



## 基于卷积神经网络的养殖鱼类品种识别模型

蔡卫明<sup>1</sup>, 庞海通<sup>1,2</sup>, 张一涛<sup>1,2</sup>, 赵建<sup>3</sup>, 叶章颖<sup>3\*</sup>

(1. 浙大宁波理工学院信息科学与工程学院, 浙江宁波 315100;

2. 浙江大学控制科学与工程学院, 浙江杭州 310027;

3. 浙江大学生物系统工程与食品科学学院, 浙江杭州 310058)

**摘要:** 随着机器学习、计算机视觉等技术的发展, 卷积神经网络(CNN)越来越多地应用于图像识别领域, 但现有的鱼类图像公共数据集资源较匮乏, 难以满足深度CNN模型优化及性能提升的需要。实验以大黄鱼、鲤、鲢、秋刀鱼和鳙为对象, 采用网络爬虫以及实验室人工拍照采集相结合的方式, 构建了供鱼种分类的基础图片数据集, 针对网络爬虫手段获取到的鱼类图像存在尺度不一、格式不定等问题, 采用图像批处理的方式对所有获取到的图像进行了统一的数据预处理, 并通过内容变换以及尺度变换对基础数据集做了数据增强处理, 完成了7 993个样本的图像采集与归纳; 在权值共享和局部连接的基础上, 构建了一个用于鱼类识别的CNN模型, 采用ReLU函数作为激活函数, 通过dropout和正则化等方法避免过度拟合。结果显示, 所构建的CNN鱼种识别模型具有良好的识别精度和泛化能力。随着迭代次数的增加, CNN模型的性能也逐步提高, 迭代1 000次达到最佳, 模型的准确率为96.56%。该模型采用监督学习的机器学习方式, 基于CNN模型, 实现了5种常见鱼类的鱼种分类, 具有较高的识别精度和良好的稳定性, 为养殖鱼类的品种识别提供了一种新的理论计算模型。

**关键词:** 鱼类识别; 卷积神经网络; 图像识别

中图分类号: S 917; TP 391

文献标志码: A

我国是世界上唯一一个水产养殖产量高于水产捕捞量的国家, 养殖总产量占世界水产养殖产量的七成以上, 海水养殖面积和淡水养殖面积合计超8 500 hm<sup>2</sup><sup>[1]</sup>。水产养殖是我国国民经济的重要支柱, 为了根据养殖鱼类的品质实现分级销售, 提升人工养殖鱼类经济效益, 在对养殖鱼类预处理和深加工之前, 对鱼进行分类是一道重要的工序。目前在养殖鱼类分类过程中, 主要采用两种技术手段, 第一种是依靠劳动力手工作业, 这种方式存在效率低下、劳务强度大、作业环境恶劣、成本高等缺陷; 第二种是采用传统的机器视觉

技术, 但该方法存在识别精度不高、泛化能力有限等不足, 导致该项技术的应用场景范围受限。随着人工智能、大数据、机器学习、计算机视觉等技术的发展, 卷积神经网络(convolutional neural network, CNN)越来越多地应用于图像识别领域, 大大提高了识别的效率和准确率, 图像数据集的丰富性以及多样性对CNN模型的性能和表达能力至关重要, 但现有的鱼类公共数据集资源较匮乏, 严重缺少训练集以及测试集样本, 难以满足深度CNN模型优化及性能提升的需要。

CNN一直是学者们研究的热点。1998年,

收稿日期: 2020-12-10 修回日期: 2021-04-09

资助项目: 国家自然科学基金(31702393, 32073028); 宁波市公益性重点类科技计划项目(2019C10098); 国家大宗淡水鱼产业技术体系专项(CARS-45-24)

第一作者: 蔡卫明(照片), 从事水生生物行为感知、环境检测及传感器技术研究, E-mail: caiwm@nit.zju.edu.cn

通信作者: 叶章颖, 从事智能化水产养殖技术与智能装备研究, E-mail: yzyzju@zju.edu.cn



Lecun 等<sup>[2]</sup>提出了 LeNetCNN 模型，该模型可以实现手写体数字的识别和分类，被认为是 CNN 的开创性工作。Krizhevsky 等<sup>[3]</sup>提出了 AlexNetCNN 模型，在网络模型搭建过程中采用了 ReLU 激活函数以及 Dropout 和 LRN 等技术，赢得了 2012 年 ImageNet 竞赛。自从 CNN 提出以来，就引起了海内外学者的极大关注，YOLO 算法的提出，为大家提供了一种更加有效的检测方法<sup>[4-8]</sup>。近年来，CNN 在图像分类、目标检测、图像语义分割等领域取得了一系列突破性的研究成果，其强大的特征学习与分类能力引起了学者们的广泛的关注<sup>[9-10]</sup>。正是由于在图像识别上的优势，CNN 的应用越来越广泛<sup>[11-14]</sup>。传统的鱼类识别方法繁琐、效率低下，基于深度学习的 CNN 有望解决该问题，并在鱼类识别领域取得了良好的效果<sup>[15-22]</sup>。但是仍然存在识别精度不高，泛化能力有限等缺陷。陈英义等<sup>[23]</sup>对 FTVGG16CNN 进行了优化，缩短了检测时间，提高了识别率，系统显示具有较好的鲁棒性，但该模型复杂度有待简化，计算成本也较高，需针对模型压缩优化方面开展深入研究。因此，本研究以 5 种常见鱼类为代表，构建供鱼种分类的基础图片数据集，并提出网络爬虫手段获取到的鱼类图像存在尺度不一、格式不定等问题的解决方法，构建一种基于 CNN 的养殖鱼类品种识别模型，对模型进行测试及性能优化分析，为研发精准、高效、可靠的养殖鱼类品种识别智能装备提供理论基础。

## 1 图像数据集构建

### 1.1 图像采集与归纳

本研究采用监督学习的机器学习方式，基于 CNN 模型，实现对 5 种常见鱼类的鱼种分类。针对现有的鱼类公共数据集资源匮乏，严重缺少训练集以及测试集样本、基础图片数据集的数量和丰富性难以满足深度 CNN 模型的需要等问题，采用网络爬虫以及实验室拍照采集相结合的方式构建了供鱼种分类的基础图片数据集，并在此基础上，通过内容变换以及尺度变换对基础数据集做数据增强处理。最终，图片数据集样本总数为 7 993 张，各鱼种图片数据集数量如表 1 所示。

其中，数据增强的内容变换采用高斯噪声变换、运动模糊变换、灰度变换、对比度变换等方式实现。数据增强的尺度变换采用垂直变换、水

表 1 图片数据集

Tab. 1 Image dataset

鱼种类别 fish category	图片数量/张 number of pictures
大黄鱼 <i>Larimichthys crocea</i>	2 054
秋刀鱼 <i>Cololabis saira</i>	468
鲢 <i>Hypophthalmichthys molitrix</i>	2 106
鲤 <i>Cyprinus carpio</i>	1 168
鳙 <i>Aristichthys nobilis</i>	2 197
数量总计 total amount	7 993

平变换以及角度变换(包含逆时针旋转 90°、逆时针旋转 180°、逆时针旋转 270°)等方式实现。通过数据增强，可以提高深度 CNN 模型的泛化能力以及表达能力，并弥补鱼类图像公共数据集资源的匮乏。

### 1.2 图像预处理

通过网络爬虫手段获取到的鱼类图像存在尺度不一、格式不定等诸多问题，需要进行统一的数据预处理。采用图像批处理的方式将所有图像的数据存储统一为“.jpg”格式，彩色图像通道数调整为三维，此外，将所有图像的大小统一缩放至 100×100 像素，并按照鱼种类别分开存储。

## 2 图像数据集构建

### 2.1 CNN 结构设计

CNN 模型的结构主要由以下 4 个部分组成。

第 1 部分为输入层，是整个 CNN 的输入部分。对于彩色图像(3 通道)，它是 3 个像素的矩阵。

第 2 部分为卷积层。原始输入由卷积内核进行特征提取，该卷积内核具有与原始输入通道相同数量的通道，从而生成更抽象的特征图。这里使用的卷积核的尺寸(下述尺寸均为像素宽度)为 5×5 和 3×3。卷积的具体实现如图 1 所示。

卷积层前后的图像尺寸计算公式：

$$N = \frac{W - F + 2P}{S} + 1 \quad (1)$$

式中， $N$  为卷积后图像尺寸 ( $N \times N$ )，输入图片大小为  $W \times W$ ，滤波器大小为  $F \times F$ ，步长为  $S$ ，填充的像素数为  $P$ 。在本研究构建的 CNN 中，填充 padding 设置为 0。

第 3 部分为池化层。池化层对输入的特征图做了降维处理，从而使特征图更小，简化了网络的参数复杂性，并提取了主要特征。池化一般包

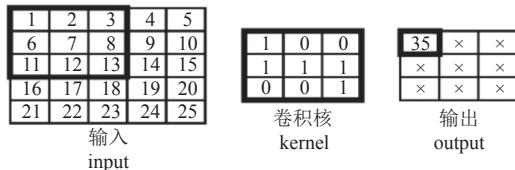


图 1 卷积计算

加粗部分为参与卷积计算的部分

Fig. 1 Convolution calculation

The bold part is the part that participates in the convolutional calculation

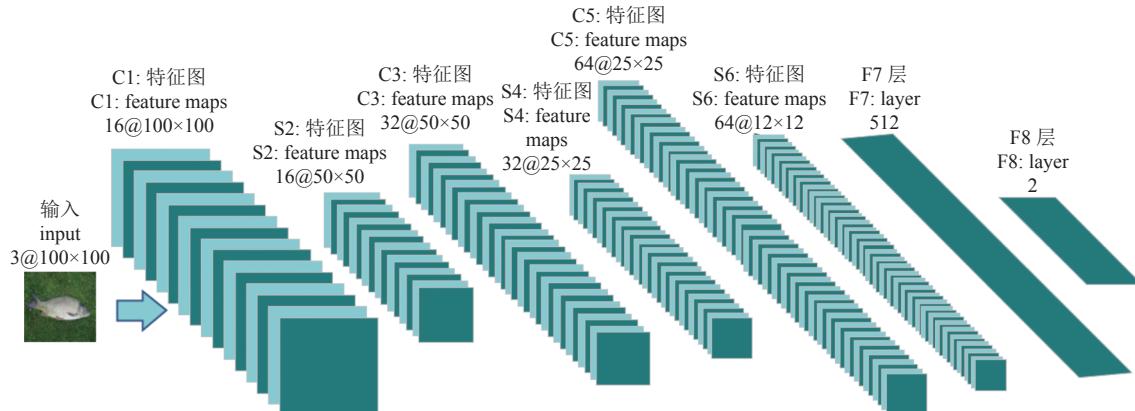


图 2 CNN 结构

Fig. 2 CNN structure

第1层: 卷积核尺寸为 $5\times 5$ , 数量为16, 填充方式为SAME, 步长为1, 以在输入层上实现特征提取。卷积特征图被作为输入并发送到池化层。池化核的大小为 $2\times 2$ , 输出为 $50\times 50\times 16$ 。

第2层: 卷积核的大小为 $5\times 5$ , 数量为32, 从而实现输入层的特征提取。卷积特征图被作为输入并发送到池化层。池化核的大小为 $2\times 2$ , 输出为 $25\times 25\times 32$ 。

第3层: 卷积核的大小为 $3\times 3$ , 数量为64, 填充方式为SAME, 步长为1, 从而实现输入层的特征提取。卷积特征图被作为输入并发送到池化层。池化核的大小为 $2\times 2$ , 输出为 $12\times 12\times 64$ 。最终输出做平坦化处理。

第4层为全连接层。

第5层为全连接层。输出判别矩阵, 并对输入图像进行识别和分类。

此外, 模型训练中的基本参数: batch\_size 设置为64, 学习率为0.001。

常见的激活函数有Sigmoid函数、tanh函数和ReLU函数等。在饱和区域中, Sigmoid函数和tanh函数均接近0, 易引起梯度消失, 并且会降低模型训练过程中的收敛速度。而ReLU的梯

括通用池化、重叠池化和空间金字塔池化, 而通用池化又包括平均池化和最大池化。在本研究构建的CNN中, 池化核选取了最大池化, 大小为 $2\times 2$ , 并且填充设置为VALID。

第4部分为全连接层。核心运算是矩阵向量的乘积, 矩阵向量从一个特征空间线性转换为另一个特征空间。

本研究构建的CNN模型分为5层(图2)。

度在大多数情况下为常数, 有助于解决深度网络中的收敛问题。另外, 由于ReLU函数可以执行稀疏表达式, 因此减少了模型的训练时间, 并提高了算法的性能。因此, 实验选择ReLU函数作为激活函数(图3)。

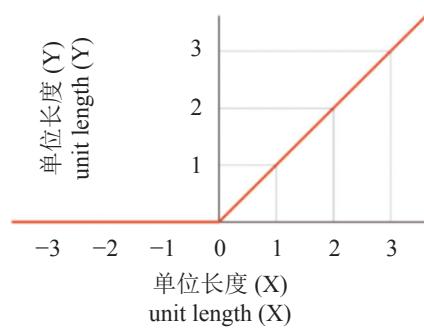


图 3 ReLU 函数

Fig. 3 ReLU function

## 2.2 损失函数和优化器的选择

在深度学习中, 损失函数的大小是衡量CNN模型的重要基础, 是衡量预测值与真实值之间接近程度的重要参数。损失函数的值越小, 模型的鲁棒性越好, 模型的性能越优。本研究构建的CNN模型选择的损失函数为交叉熵损失函数。交

叉熵损失 (loss) 公式:

$$\text{loss} = - \sum_{i=1}^n y_i \ln(y_i) \quad (2)$$

式中,  $y_i$  代表预期输出,  $y_i$  代表网络模型预测结果。

本研究所构建的 CNN 模型选用的优化器是 Adam 优化函数。Adam 是一阶优化算法, 可以代替传统的随机梯度下降过程。它可以基于训练数据迭代地更新神经网络权重, 高效且内存消耗更少。

### 2.3 Dropout 和正则化

Dropout 和正则化是优化具有深层结构的 CNN 的重要方法, 并且是抑制网络过度拟合的重要手段。在 CNN 模型的正向传播和反向传播的学习过程中, Dropout 将隐藏层的部分权重或输出设置为 0, 从而减少了节点之间的相互依赖性, 降低了网络的结构风险, 并且减少了 CNN 的计算成本 (图 4)。这意味着每轮梯度下降迭代时会将训练数据分为几批, 然后分批迭代。迭代每批数据时, 会部分删除部分隐藏层的神经元, 然后使用新模型迭代更新参数  $W$  和  $b$ 。

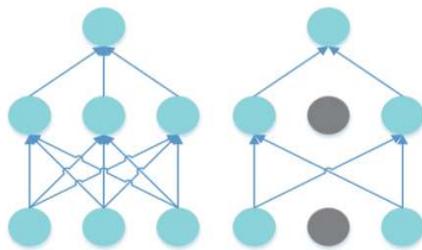


图 4 Dropout 策略

蓝色圆点代表活跃神经元, 灰色圆点代表未被激活的神经元, 连接线代表网络模型正向传递的连接关系

Fig. 4 Dropout strategy

The blue dot represents active neurons, the gray dot represents inactive neurons, and the connection line represents the connection relationship of forward transmission of the network model

正则化是避免模型过度拟合的另一种常用方法。主要原理是在损失函数的末尾添加惩罚项, 以防止 CNN 模型过拟合。如果添加了  $L_1$  范数, 则称为  $L_1$  正则化。如果添加了  $L_2$  范数, 则称为  $L_2$  正则化。本研究使用  $L_2$  正则化。 $L_2$  正则化的公式:

$$J = J_0 + L_2 = \|XW - y\|_2^2 + \alpha\|W\|_2 \quad (3)$$

式中, 原始损失函数为  $J_0$ ,  $L_2$  是  $L_2$  正则化项,  $J$  为添加正则化后的损失函数,  $X$  为输入,  $W$  为权重矩阵,  $y$  为输出,  $\alpha$  为学习率。

### 2.4 分类器的设计

本研究的目的是对输入图像进行分类。实验中, Softmax 函数被用作分类器。它是面向多分类的分类器。Softmax 函数也称为归一化函数, 是对数函数的泛化。它的主要功能是将任何输入向量映射到 0~1 的概率, 从而实现多重分类的目的。Softmax 函数 ( $S_i$ ) 的定义:

$$S_i = \frac{e^{V_i}}{\sum_i^C e^{V_i}} \quad (4)$$

式中,  $V_i$  为上级输出单元的输出,  $i$  为类别索引,  $C$  为类别总数。Softmax 将多类别的输出值转换为 0~1。例如, 线性分类器模型的最终输出层包含 3 个输出值:

$$V = \begin{bmatrix} -1 \\ 2 \\ -3 \end{bmatrix} \quad (5)$$

经过 Softmax 处理后, 这些值将转换为相对概率:

$$S = \begin{bmatrix} 0.0426 \\ 0.7439 \\ 0.2135 \end{bmatrix} \quad (6)$$

Softmax 的输出表示不同类别之间的相对概率。可以清楚地看出最大值为 0.7439, 即该鱼种的类别置信度为 0.7439, 为输出类别。

### 3 讨论

根据先前确定的 CNN 结构和算法参数, 将 “.jpg” 格式的图片数据集发送至 CNN 模型进行训练。训练集与测试集的比例为 9:1。实验所依赖的实验环境条件见表 2。

在学习率和批量大小等参数保持不变的前提下, 将迭代次数分别设置为 100、300、500、700 和 1 000 次, 获得了 5 个模型, 每个模型的训练集准确率曲线和损失曲线如图 5 所示。

表 2 实验环境

Tab. 2 Experimental environment

类型 types	详述 details
硬件环境 hardware environment	CPU: AMD Ryzen 5 3600 6-Core RAM: 16.0 GB GPU: NVIDIA GeForce RTX2060 (6GB)
软件环境 software environment	Windows 10 Tensorflow-GPU 1.14.0
编程语言 programming language	Python 3.6.5

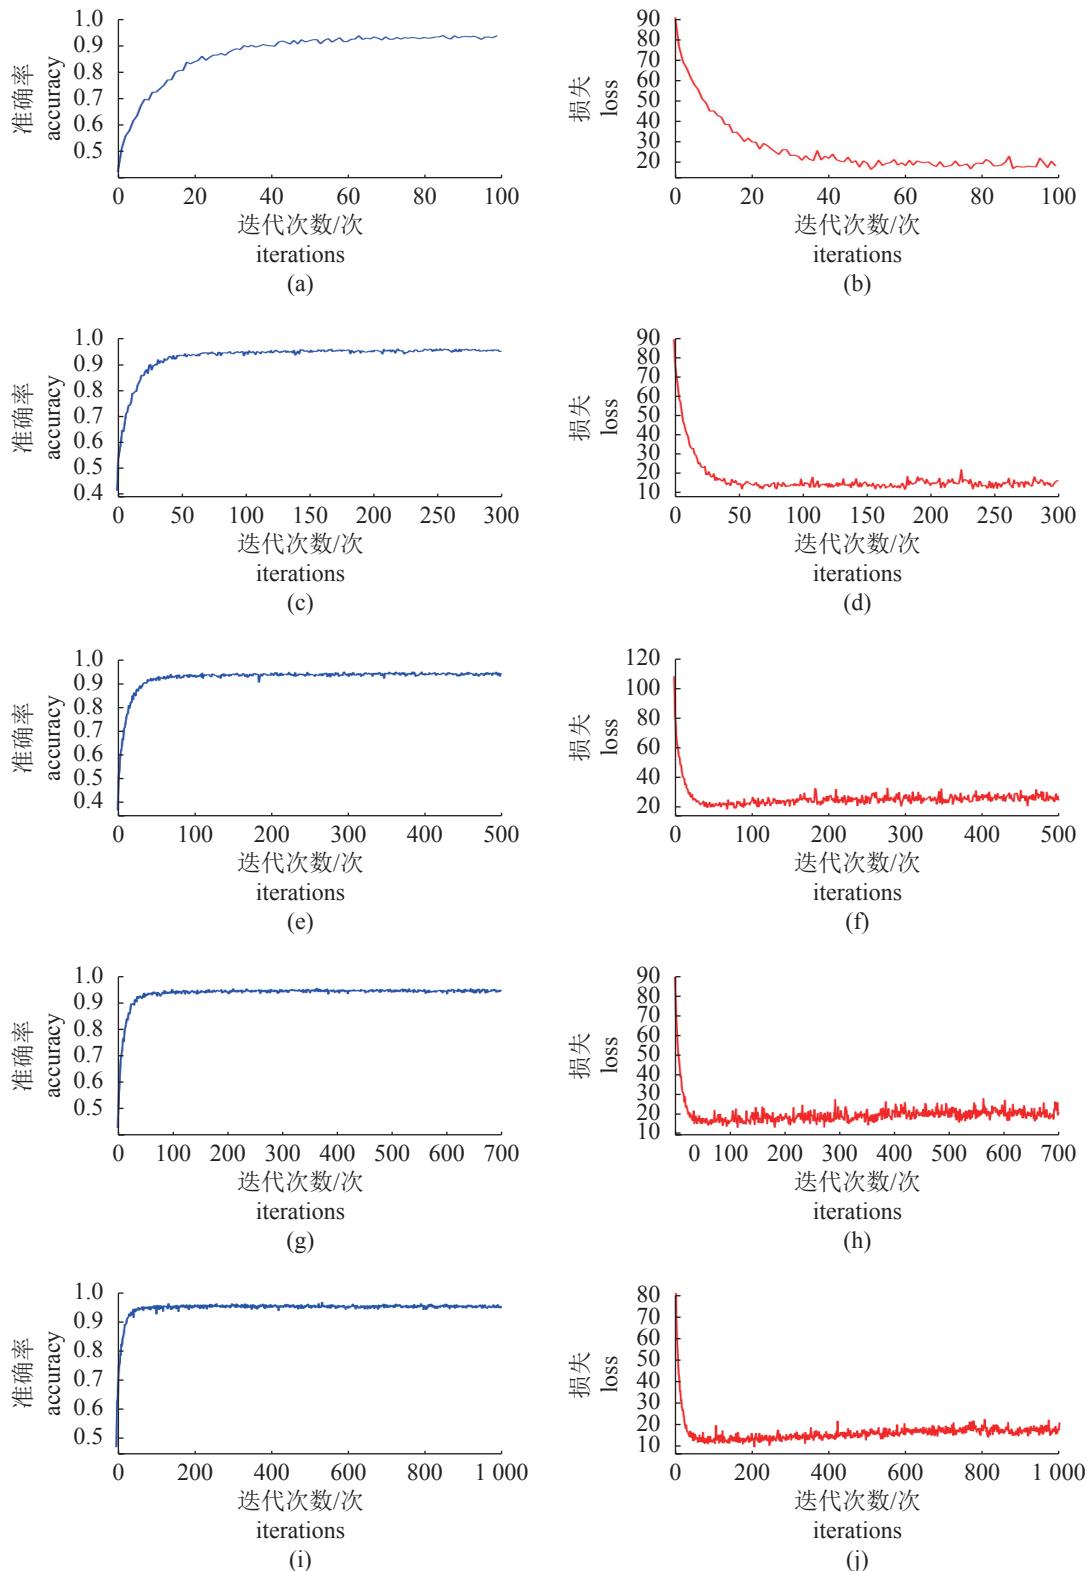


图 5 准确率曲线以及损失曲线

(a)~(b) 迭代次数 100; (c)~(d) 迭代次数 300; (e)~(f) 迭代次数 500; (g)~(h) 迭代次数 700; (i)~(j) 迭代次数 1 000; (a) (c) (e) (g) (i) 训练集准确率曲线, (b) (d) (f) (h) (j) 损失曲线

Fig. 5 Accuracy curve and loss curve

(a)~(b) iterations 100; (c)~(d) iterations 300; (e)~(f) iterations 500; (g)~(h) iterations 700; (i)~(j) iterations 1 000; (a) (c) (e) (g) (i) training set accuracy, (b) (d) (f) (h) (j) loss curve

随着迭代次数不断增加, CNN 模型的性能不断提高(表3)。权衡 5 个模型的识别精度和计算消耗, 选择具有 1 000 次迭代的模型作为最终模型, 模型的准确率为 0.9656, 虽然低于文献<sup>[23]</sup>中报道的模型准确率(0.9766), 但测试准确率相差无几, 并且本研究所用模型计算成本相对更低, 系统鲁棒性等相对更好。此外, 相对于已有文献<sup>[20-23]</sup>中所提到的鱼类识别模型, 本研究中提出的鱼种识别模型涵盖了新的鱼种类别, 即大黄鱼、鲤、鲢、秋刀鱼和鳙, 所提出的鱼种识别模型在保持较高准确率的同时, 仅包含 5 层网络结构, 模型复杂程度较低。

表3 不同迭代次数下的识别精度

Tab. 3 Recognition accuracy under different iteration

准确率 accuracy	迭代次数/次 iterations				
	100	300	500	700	1000
训练集准确率 train accuracy	0.9871	0.9909	0.9923	0.9934	0.9942
测试集准确率 test accuracy	0.9312	0.9426	0.9453	0.9523	0.9656

## 4 结论

采用网络爬虫和实验室拍照采集相结合的方式, 构建了供养殖鱼类分类的基础图像数据集, 并通过内容变换以及尺度变换对基础数据集做数据增强处理, 弥补了现有鱼类公共数据集内的养殖鱼类图像匮乏, 为开展鱼种识别模型优化研究提供了更丰富的训练集和测试集样本。

实验建立了基于 CNN 的养殖鱼品种识别模型。该模型共有 5 层, 在模型构建过程中, 采用正则化和 Dropout 方法来避免模型过度拟合, 输入图像经过 3 层卷积层和 2 层全连接层后, 通过 Softmax 分类器输出识别向量, 从而输出识别结果。

采用监督学习的机器学习方式, 基于 CNN 模型实现对 5 种常见鱼类的鱼种分类, 分析了在不同迭代下识别精度的差异。考虑到计算成本和模型准确性, 1 000 次迭代测试效果达到最佳, 模型的准确率为 0.9656, 具有较高的识别精度和良好的稳定性, 并且模型本身具有一定程度的鱼种推广可能性, 为养殖鱼类的品种识别提供了一种新的理论计算模型。

(作者声明本文无实际或潜在的利益冲突)

## 参考文献 (References):

- [1] 戴瑛, 裴兆斌. 渔业法新论 [M]. 南京: 东南大学出版社, 2017: 282.
- [2] Dai Y, Pei Z B. A new discussion on Fishery Law[M]. Nanjing: Southeast University Press, 2017: 282 (in Chinese).
- [3] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [4] Chang F H, Broadbent F E. Influence of trace metals on carbon dioxide evolution from a Yolo soil[J]. *Soil Science*, 1981, 132(6): 416-421.
- [5] Chang F H, Broadbent F E. Influence of trace metals on carbon dioxide evolution from a Yolo soil[J]. *Soil Science*, 1981, 132(6): 416-421.
- [6] Sommer T, Harrell B, Nobriga M, et al. California's Yolo Bypass: evidence that flood control can be compatible with fisheries, wetlands, wildlife, and agriculture[J]. *Fisheries*, 2001, 26(8): 6-16.
- [7] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of 2016 IEEE conference on computer vision and pattern recognition. Las Vegas: IEEE, 2016: 779-788.
- [8] Sichkar V N, Kolyubin S A. Real time detection and classification of traffic signs based on YOLO version 3 algorithm[J]. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2020, 20(3): 418-424.
- [9] 李庆忠, 李宜兵, 牛炯. 基于改进YOLO和迁移学习的水下鱼类目标实时检测[J]. 模式识别与人工智能, 2019, 32(3): 193-203.
- [10] Li Q Z, Li Y B, Niu J. Real-time detection of underwater fish based on improved YOLO and transfer learning[J]. *Pattern Recognition and Artificial Intelligence*, 2019, 32(3): 193-203 (in Chinese).
- [11] Kim Y. Convolutional Neural Networks for Sentence Classification [J]. e-print arXiv, 2014(2):1-6.
- [12] Oquab M, Bottou L, Laptev I, et al. Learning and transferring mid-level image representations using convolutional neural networks[C]//Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 1717-1724.
- [13] 吕国豪, 罗四维, 黄雅平, 等. 基于卷积神经网络的正则化方法[J]. *计算机研究与发展*, 2014, 51(9): 1891-1900.

- 1900.
- Lü G H, Luo S W, Huang Y P, et al. A novel regularization method based on convolution neural network[J]. *Journal of Computer Research and Development*, 2014, 51(9): 1891-1900 (in Chinese).
- [12] 谢宝剑. 基于卷积神经网络的图像分类方法研究 [D]. 合肥: 合肥工业大学, 2015.
- Xie B J. The research of image classification methods based on convolution neural network[D]. Hefei: Hefei University of Technology, 2015 (in Chinese).
- [13] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. *计算机应用*, 2016, 36(9): 2508-2515, 2565.
- Li Y D, Hao Z B, Lei H. Survey of convolutional neural network[J]. *Journal of Computer Applications*, 2016, 36(9): 2508-2515, 2565 (in Chinese).
- [14] 许可. 卷积神经网络在图像识别上的应用的研究 [D]. 杭州: 浙江大学, 2012.
- Xu K. A dissertation submitted to Zhejiang University for the degree of master of engineering[D]. Hangzhou: Zhejiang University, 2012 (in Chinese).
- [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 W H, Cai M S, Yan S, et al. Fish classification based on deep convolutional neural network and transfer learning[J]. *Journal of Fuqing Branch of Fujian Normal University*, 2019(5): 30-38 (in Chinese).
- [16] 林明旺. 基于卷积神经网络的鱼类图像识别与分类[J]. 电子技术与软件工程, 2017(6): 82-83.
- Lin M W. Image recognition and classification of fish based on convolutional neural network[J]. *Electronic Technology & Software Engineering*, 2017(6): 82-83 (in Chinese).
- [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 T. Research on fish recognition based on deep learning[D]. Hangzhou: Zhejiang University of Technology, 2019 (in Chinese).
- [18] Lopresti R, Asaro N J, Price A, et al. Identification of variables contributing to increased vitamin D concentrations in fish and fish ingredients[J]. *Animal Feed Science and Technology*, 2020, 266: 114506.
- [19] Grema H A, Kwaga J K P, Bello M, et al. Understanding fish production and marketing systems in North-western Nigeria and identification of potential food safety risks using value chain framework[J]. *Preventive Veterinary Medicine*, 2020, 181: 105038.
- [20] 王文成, 蒋慧, 乔倩, 等. 基于深度学习的鱼类识别与检测的算法研究[J]. 信息技术与网络安全, 2020, 39(8): 57-61,66.
- Wang W C, Jiang H, Qiao Q, et al. Research on fish recognition and detection algorithm based on deep learning[J]. *Information Technology and Network Security*, 2020, 39(8): 57-61,66 (in Chinese).
- [21] 林明旺. 深度学习在鱼类图像识别与分类中的应用[J]. *数字技术与应用*, 2017(4): 96-97.
- Lin M W. Application of deep learning in image recognition and classification of fish[J]. *Digital Technology and Application*, 2017(4): 96-97 (in Chinese).
- [22] 郭锦熙. 基于特征提取与 CNN 模型融合的海洋鱼类识别 [D]. 天津: 天津工业大学, 2019.
- Guo J X. Marine Fish Identification based on feature extraction and CNN model fusion[D]. Tianjin: Tianjin Polytechnic University, 2019 (in Chinese).
- [23] 陈英义, 龚川洋, 刘烨琦, 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 Y Y, Gong C Y, Liu Y Q, et al. Fish identification method based on FTVGG16 convolutional neural network[J]. *Transactions of the Chinese Society of Agricultural Machinery*, 2019, 50(5): 223-231 (in Chinese).

## Recognition model of farmed fish species based on convolutional neural network

CAI Weiming<sup>1</sup>, PANG Haitong<sup>1,2</sup>, ZHANG Yitao<sup>1,2</sup>, ZHAO Jian<sup>3</sup>, YE Zhangying<sup>3\*</sup>

(1. School of Information Science and Engineering, NingboTech University, Ningbo 315100, China;

2. College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China;

3. College of Biosystems Engineering and Food Science, Zhejiang University, Hangzhou 310058, China)

**Abstract:** With the development of artificial intelligence, big data, machine learning, computer vision and other technologies, convolutional neural network (CNN) is increasingly used in the field of image recognition, which greatly improves the efficiency and accuracy of recognition. Machine learning is data-driven and requires large amounts of data as a basis for experimentation. The richness and diversity of image data sets are crucial to the performance and expressive ability of convolutional neural network models. However, the existing fish image data set resources are relatively scarce, and the training set and test set samples are severely lacking. This makes it difficult to train neural network models, and it is difficult to meet the needs of deep convolutional neural network model optimization and performance improvement. A basic image data set for fish species classification was constructed by using a combination of web crawlers and manual camera collection in the laboratory. *Larimichthys crocea*, *Hypophthalmichthys molitrix*, *Cyprinus carpio*, *Cololabis saira* and *Aristichthys nobilis* were used as the test objects in this paper. First, we used web crawlers on the web to obtain pictures of these species of fish, and then, in a laboratory environment, we used cameras to take a large number of photos of these species of fish. In view of the problems of different scales and uncertain formats of images, image batch processing, unified data preprocessing was performed on all the acquired images, and the basic data set was enhanced through content transformation and scale transformation. The dataset was further enriched through this process and the image collection and induction of 7 993 samples were completed. On the basis of parameter sharing and local connectivity, a convolutional neural network model for fish recognition is constructed; the ReLU function was used as the activation function to improve the performance of the algorithm; the dropout and regularization were used to avoid overfitting. The test results showed that: the convolutional neural network fish species recognition model constructed in this study have good recognition accuracy and generalization ability. As the number of iterations increased, the performance of the convolutional neural network model gradually improved. It reached the best when the number of iterations came to 1 000. The accuracy of the model was 96.56%. The model adopted the machine learning method of supervised learning. Based on the CNN model, it realized the classification of five common fish species, with high recognition accuracy and good stability. The model has provided a new theoretical calculation model for the species identification of farmed fish.

**Key words:** fish identification; convolutional neural network, CNN; image identification

**Corresponding author:** YE Zhangying. E-mail: yzyzju@zju.edu.cn

**Funding projects:** National Natural Science Foundation of China (31702393, 32073028); Ningbo Municipal Public Welfare Key Science and Technology Plan Project (2019C10098); National Bulk Freshwater Fish Industry Technology System Special Project (CARS-45-24)