

基于注意力机制的污水微型动物识别方法

肖蕾*, 蓝宗苗

广东技术师范大学自动化学院, 广东 广州 510665

摘要 为了精准掌握污水处理系统活性污泥中微型动物的种类,及时调整污水处理工艺,针对传统机器学习需要人工设计特征、提取特征、设计分类器等复杂过程的弊端,提出一种基于注意力机制和迁移学习相结合的污水活性污泥中微型动物的深度学习识别方法。在迁移学习的基础上,通过对传统的 VGG16 模型添加注意力模块(SE-Net block),调整输出模块,采用数据增强方法扩充数据集。实验结果表明:相比于改进前的模型,改进后的模型(T-SE-VGG16)能够准确识别不同类型污水活性污泥中的微型动物,测试准确率为 98.21%,提高了识别精度,缩短了训练时间,模型收敛速度快,泛化能力强。结果证实了 T-SE-VGG16 模型对污水活性污泥中的微型动物识别的可行性和可靠性。

关键词 深度学习; 迁移学习; 注意力机制; 活性污泥; 微型动物识别

中图分类号 TP389

文献标志码 A

DOI: 10.3788/LOP212628

Identification of Sewage Microorganisms Using Attention Mechanism

Xiao Lei*, Lan Zongmiao

College of Automation, Guangdong Polytechnic Normal University, Guangzhou 510665, Guangdong, China

Abstract To accurately identify microorganism species in the activated sludge of sewage treatment systems and modify the wastewater treatment process in real-time, using traditional machine learning methods is a challenge because of various complicated processes. In this study, a deep learning approach based on the integration of attention mechanism and transfer learning is proposed to accurately identify the species of microorganisms in sewage-activated sludge by overcoming the requirements of developing features manually, extracting features, designing classifiers, and other complicated processes. On the basis of transfer learning, the conventional VGG16 model is enhanced by including the attention module (SE-Net block) and modifying the output module, and the dataset is expanded using the data improvement approach. Experimental findings demonstrate that compared with the model before the enhancement, the enhanced model (T-SE-VGG16) can accurately recognize microorganisms in various types of sewage-activated sludge with a test accuracy of 98.21%, which enhances the recognition accuracy and reduces the training time. The model converges rapidly and has a strong generalization ability in terms of training time. Moreover, the T-SE-VGG16 model's feasibility and reliability for the identification of microorganisms in sewage-activated sludge are verified.

Key words deep learning; transfer learning; attention mechanism; activated sludge; micro-animal identification

1 引言

活性污泥法是一种废水生物处理工艺,因具有成本低、处理效果好的优点,我国超过 80% 的污水处理厂都使用了活性污泥法^[1-2]。活性污泥中的微型动物(包括原、后生动物)的数量、活性、种类会随着工艺运行条件的变化出现明显的波动^[3]。因此对污水处理系统活性污泥中的微型动物进行准确识别对于指导污水处理工艺具有重要的意义。

传统的微生物识别方法是研究人员在显微镜下观

察微生物,根据其形状进行识别,此方法的主观因素多,主要取决于研究人员的经验、工作量、情绪,效率低^[4]。随着计算机技术的发展,机器学习技术被广泛地应用于微型动物图像分析任务。Ginoris 等^[5-6]运用判别式分析、神经网络、决策树多变量统计技术对目标微生物的形态学参数进行分析来实现分类,该方法对非固着原生动类群和后生动物类群均有较好的识别效果。刘俊^[7]从水中微生物图像提取形态、纹理等特征后,使用遗传模拟退火算法优化,最后利用 BP 神经网络进行识别。陈瑶^[8]从活性污泥中常见原后生动物

收稿日期: 2021-09-28; 修回日期: 2021-10-23; 录用日期: 2021-11-08; 网络首发日期: 2021-11-22

基金项目: 2021 年度广东省普通高校重点研究领域专项(新一代信息技术)(2021ZDZX1033)

通信作者: *2650782969@qq.com

图像提取特征后,采用决策树进行分类。这些方法都有着传统机器学习方法的局限性:需要人工提取图像的形状、纹理特征,再设计分类器进行识别,此过程繁琐且识别率不高。针对低对比度图像,Wang等^[9]运用Canny算子和数学形态学分别对图像进行分割,Wang^[10]运用Canny算子和迭代阈值对图像进行分割。两种方法均对分割后的两幅图像进行小波变换融合,融合图像能尽可能地保留原始图像信息,突出原始图像边缘,避免了过分割,都取得了较好的分割效果。

近年来,深度学习在微生物图像分析任务中得到了广泛的研究和发展。Xu等^[11]提出了一种生成对抗网络增强框架(EF-GAN),该框架将几何变换方法和生成对抗网络相结合用于环境微生物图像增强,显著提高了图像的质量和分辨率,使用VGG16网络和ResNet50网络进行测试,分类精度均得到提高。Zhao等^[12]使用多个卷积神经网络(CNN)和visual transformer(VT)模型,对包含21种环境微生物的小样本数据集进行分类,其中Xception模型在该数据集表现出了好的分类效果。Liang等^[13]同样使用该数据集对环境微生物进行分类,使用数据增强技术扩充数据集,并使用遗传算法优化Inception-v3模型的全连接层神经元数量和丢弃率,改进后的Inception-v3模型获得了92.9%的准确率。Kulwa等^[14]提出了一种将手工特征和深度学习特征相结合的新的成对深度学习特征技术,来分析微生物图像。该技术使用Shi和Tomasi兴趣点,从以兴趣点位置为中心的patch中提取深度学习特征;然后利用Delaunay三角定理和直线几何定理对邻近的深度学习

特征进行配对;再将成对特征与原始特征相结合,形成每幅图像的联合成对特征;最后利用支持向量机、k-神经网络和随机森林分类器,验证了该技术的有效性。

目前,国内外关于污水处理系统活性污泥中的微型动物识别的相关研究主要集中在传统机器学习方法,深度学习在其他领域微生物图像分析任务的成功给本文带来启示。卷积神经网络能自动实现特征提取,避免了人工设计特征、提取特征、设计分类器等复杂的过程,对描述微生物复杂的形态特征和结构具有更强的鲁棒性^[15]。因此,本文将深度学习方法用于污水处理系统活性污泥中的微型动物的识别,选择了深度学习分类模型中的VGG16网络,在原模型的基础上添加注意力机制模块(SE-Net block)并修改输出模块,再结合迁移学习方法,最终获得了比原模型识别准确率更高、泛化能力更强的识别模型。

2 模型构建

2.1 数据集

由于目前缺少标准可靠的污水微型生物图像数据集,本研究通过在污水处理厂采集水样,使用光学显微镜拍摄获得清晰的微型动物图像。由于所获得的图像包含冗余信息,对原始图像进行适当的裁剪,最后获得了包含轮虫(Rotifer)、游仆虫(Euplotes)、粗袋鞭虫(Peranema trichophonum)、钟虫(Vorticella)、漫游虫(Litonotus)、线虫(Nematode)6种类型的常见微型动物图像数据集,共有图片634张,各类微型动物图像如图1所示。




图1 微型动物图像。(a)轮虫;(b)游仆虫;(c)粗袋鞭虫;(d)钟虫;(e)漫游虫;(f)线虫

Fig. 1 Images of micro-animals. (a) Rotifer; (b) Euplotes; (c) Peranema trichophonum; (d) Vorticella; (e) Litonotus; (f) Nematode

深度学习模型的训练需要大量数据作为支撑。数据增强能在一定程度上弥补数据集样本过少的不足,可大大改善模型的泛化能力,降低网络出现过拟合现象的风险,提高鲁棒性^[16]。本文获得的原始数据集为

小样本数据集,通过对现有图片进行水平翻转、旋转90°、旋转180°、增加适当的高斯噪声4种数据增强方式扩充图片数量。以粗袋鞭虫为例,数据增强效果如图2所示。数据增强后的数据集共有图片3170张,分



图2 数据增强效果。(a)原图;(b)水平翻转;(c)旋转90°;(d)旋转180°;(e)增加适当的高斯噪声

Fig. 2 Data enhancement effect. (a) Original image; (b) flipping horizontally; (c) rotating 90°; (d) rotating 180°; (e) adding appropriate Gaussian noise

别为轮虫 675 张、游仆虫 600 张、粗袋鞭虫 665 张、钟虫 480 张、漫游虫 480 张、线虫 270 张。

2.2 注意力机制

近几年,注意力机制被广泛地使用在深度学习任务中。注意力机制可以获取到输入特征矩阵各部分重要性的差异,从而赋予不同的权重,提取出更加关键和更有区分性的信息,使模型作出更加准确的判断。

Squeeze-and-Excitation Network (SE-Net)^[17]是由 Momenta 公司胡杰团队提出的一个实现注意力机制的网络结构,赢得了 2017 年 ImageNet 竞赛图像分类

任务的冠军。SE-Net 中的关键结构 SE-Net block 利用了注意力机制的思想,显式地建模特征通道之间的相互依赖关系,并通过学习的方式来自动获取到每个特征通道的重要性差异,然后依照这个差异去增强有用的特征同时减弱对当前任务用处不大的特征^[18]。SE-Net 的结构如图 3 所示。通过对特征通道数为 C' 的输入特征矩阵 X 进行一系列的卷积变换后,得到通道数为 C 的特征矩阵 U 。实现注意力机制的结构包括挤压 (Squeeze)、激励 (Excitation) 和特征重标定 (Scale) 3 部分。




图 3 挤压激励网络

Fig. 3 Squeeze-and-Excitation Network

对于挤压,分别对特征矩阵 U 的每一个通道进行全局平均池化操作,公式为

$$s_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), \quad (1)$$

式中: H 为特征矩阵的高; W 为特征矩阵的宽; u_c 为特征矩阵 U 中第 c 个特征图; s_c 为第 c 个特征图的挤压结果。每一个通道的特征图都被挤压成一个具有全局感受野的实数,每一个通道的挤压结果组合成一个长度为 c 的向量 s 。

对于激励,将挤压操作后的向量 s 依次通过全连接层、激活函数 ReLU、全连接层、激活函数 Sigmoid,实现激励操作,获得长度为 c 的向量 e 。激励操作的表达式为

$$e = \sigma[F_2 \delta(F_1 s)], \quad (2)$$

式中: F_1 为第一次全连接层操作; F_2 为第二次全连接层操作; δ 为激活函数 ReLU; σ 为激活函数 Sigmoid。

对于特征重标定,最后将激励操作所获得的向量 e 通过乘法逐通道加权到原始输入特征矩阵上,表达式为

$$u_c' = e_c u_c, \quad (3)$$

式中: e_c 为激励向量 e 的第 c 个值; u_c' 为输出矩阵 U' 的第 c 个特征图。这样完成在通道维度上对原始特征的重标定,获得输出矩阵 U' 。

2.3 改进的 VGG16 模型

VGG16 模型^[19]使用多个小卷积核代替大卷积核,具有较深的网络层,有利于提高图像分类的准确度。但是 VGG16 模型的三个全连接层增加了大量的参数,导致在训练时需要花费更多的时间,占用更多的存

储空间^[20]。为了增强模型的特征提取能力,减少参数量以减少训练时间和内存资源,在 VGG16 网络上添加注意力机制模块并只保留一层全连接层,最终形成适合微型动物识别分类任务的改进 VGG16 网络模型。模型改进前后的参数量对比如表 1 所示,改进前模型参数量约为改进后的 4.7 倍。

表 1 模型改进前后参数量对比

Table 1 Comparison of number of parameters before and after model improvement

Model	Number of parameters
Before improvement	70305606
After improvement	14931334

改进前后的模型结构对比如图 4 所示,点虚线框内为改进的内容。改进后的模型整体结构如下:输入的图像尺寸为 $224 \times 224 \times 3$,被具有 64 个卷积核的卷积层卷积 2 次和 ReLU 激活,输出尺寸大小为 $224 \times 224 \times 64$;经过最大池化层池化,图像尺寸减半,输出尺寸变为 $112 \times 112 \times 64$;被具有 128 个卷积核的卷积层卷积 2 次和 ReLU 激活,输出尺寸大小为 $112 \times 112 \times 128$;经过最大池化层池化,输出尺寸变为 $56 \times 56 \times 128$;被具有 256 个卷积核的卷积层卷积 3 次和 ReLU 激活,输出尺寸大小为 $56 \times 56 \times 256$;经过最大池化层池化,输出尺寸变为 $28 \times 28 \times 256$;被具有 512 个卷积核的卷积层卷积 3 次和 ReLU 激活,输出尺寸大小为 $28 \times 28 \times 512$;经过最大池化层池化,输出尺寸变为 $14 \times 14 \times 512$;被具有 512 个卷积核的卷积层卷积 3 次和 ReLU 激活,输出尺寸大小为 $14 \times 14 \times 512$;经过最

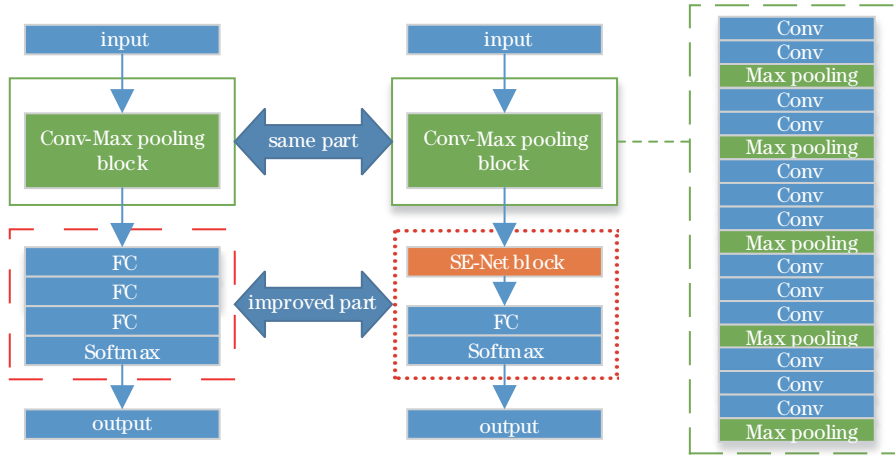


图 4 VGG16模型改进前后对比图

Fig. 4 Comparison images of VGG16 model before and after improvement

大池化层池化,输出尺寸变为 $7 \times 7 \times 512$;经过 SE 网络模块,输出尺寸为 $7 \times 7 \times 512$;然后进行打平(flatten),将数据变成一维向量 $7 \times 7 \times 512 = 25088$;再经过 $1 \times 1 \times 6$ 的全连接层,Dropout为0.5,最后通过Softmax分类器输出预测结果。

2.4 迁移学习

迁移学习是一种机器学习方法,把一个领域(即源领域)的知识迁移到另外一个领域(即目标领域),使得目标领域能够取得更好的学习效果^[21]。根据技术方法,可以把迁移学习分为4种方式:基于样本迁移、基于特征迁移、基于模型迁移和基于关系迁移。本文采用的是基于模型迁移的方法,通过找到源领域和目标领域中的共享参数或先验关系,以实现迁移,所以此方法也叫基于参数的迁移学习方法。迁移学习常用的训练策略有3种:第1种是冻结预训练模型的全部卷积

层,只训练全连接层;第2种是冻结预训练模型的部分卷积层,训练剩余的卷积层和全连接层;第3种是加载预训练模型参数以后,训练整个网络参数^[22]。本文采用第1种训练策略。

针对微型动物识别任务,改进的VGG16模型与迁移学习相结合的具体实现如图5所示。首先,利用ImageNet大型图像数据集对VGG16整个网络进行训练,获得预训练模型;接着,采用基于模型的迁移学习方法,将预训练模型VGG16全连接层前5个“卷积-池化”块的参数迁移到改进的VGG16模型中作为初始化参数;最后,在建立的数据增强微型动物图像数据集上完成改进模型的训练,训练的策略是冻结参数迁移层的所有参数,只训练改进部分。最终获得注意力机制SE模块和迁移学习相结合的改进VGG16网络模型(T-SE-VGG16)。

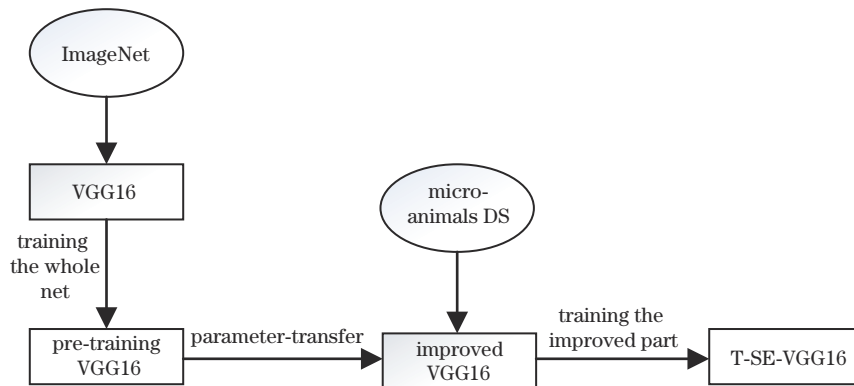


图 5 基于迁移学习的改进 VGG16 模型的训练过程

Fig. 5 Training process of improved VGG16 model based on transfer learning

3 结果与分析

3.1 实验环境

实验硬件环境:操作系统为Ubuntu;处理器为Intel(R)Core(TM)i5-8500 CPU @ 3.00 GHz(6 CPUs), 3.0 GHz;GPU为NVIDIA GeForce RTX 2080Ti。软件

环境:深度学习框架为TensorFlow2.4.1;Python3.7.1。

3.2 实验设置

超参数的选择对模型的训练及性能有很重要的影响。学习率(learning rate)是在优化算法中更新网络权重的幅值大小,学习率设置过大可能导致模型无法收敛,设置太小则导致模型收敛速度慢,需要更长的训

练时间。批次大小(batch size)是每一次训练神经网络送入模型的样本数,在卷积神经网络中,大批次通常可使网络更快收敛,但由于内存资源的限制,批次过大可能会导致内存不够用或程序内核崩溃。Dropout通常会在全连接层之间使用,防止过拟合,单元数量越多的隐藏层有更大的概率过拟合,需要更小的随机失活概率。

在数据集上进行系列实验,最终选取学习率为 0.0001,批次大小为 32,Dropout 为 0.5。设置实验训练的迭代次数为 100。

3.3 实验结果与分析

为了验证对数据集进行数据增强的方法的有效性,分别利用原数据集和数据增强后的数据集对 T-SE-VGG16 模型进行训练,所获得的模型准确率如表 2 所示。从表 2 可以看出,相比于原始数据集,数据增强后的数据集训练所获得的模型准确率有大幅度的提高。将数据增强方法获得的更多数据输入模型进行训练,模型可以获得更好的性能,验证了数据增强方法的有效性。

表 2 数据增强前后分类性能对比

Table 2 Comparison of classification performance before and after data augmentation

Dataset	Accuracy / %
Original	93.05
Augmentation	98.21

为了验证所提改进模型 T-SE-VGG16 的有效性,对 VGG16 原模型、迁移学习模型 T-VGG16、添加 SE 模块和未删减输出模块的全连接层及使用迁移学习方法的模型 T-SE-VGG16(uncut)在数据增强数据集上进行实验对比。训练过程中,训练集和验证集的准确率变化分别如图 6、7 所示,训练集和验证集的损失值变化分别如图 8、9 所示。从图 6~9 可以看出:T-SE-VGG16 模型的训练集和测试集的准确率都随着训练




图 6 训练集上准确率变化过程

Fig. 6 Accuracy change process on training set




图 7 验证集上准确率变化过程

Fig. 7 Accuracy change process on validation set

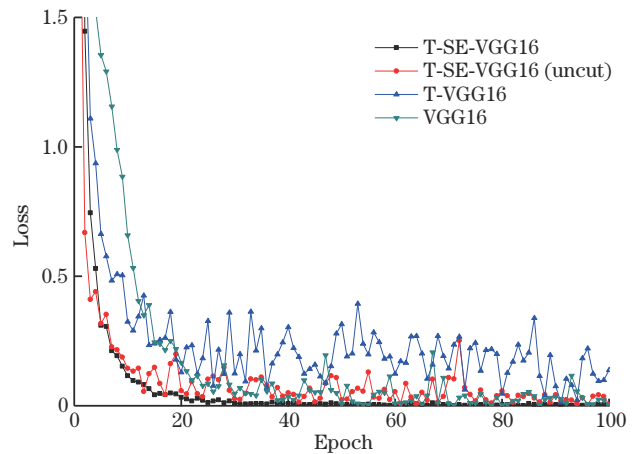


图 8 训练集上损失值变化过程

Fig. 8 Loss change process on training set

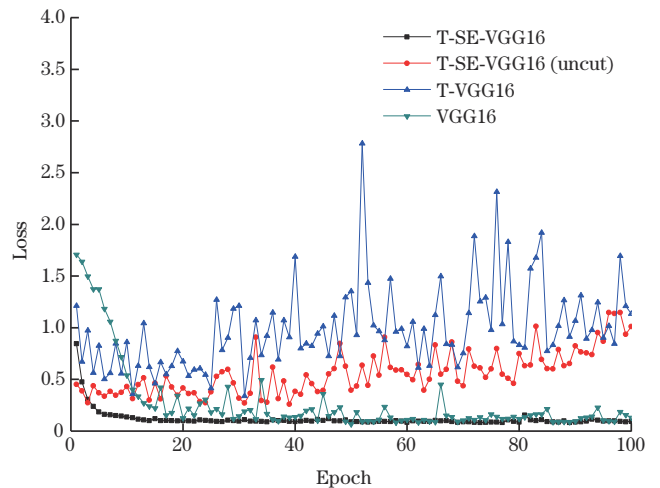


图 9 验证集上损失值变化过程

Fig. 9 Loss change process on validation set

迭代轮次的增加快速提高,最终都达到了较高的数值并且数值接近;训练集和测试集的损失值都随着训练迭代轮次的增加快速减小,最终都达到了很低的数值并且数值接近;在第 30 个轮次时,训练集和测试集的

准确率和损失值已经很稳定,模型收敛,网络没有出现拟合现象。T-VGG16模型在训练集和测试集的准确率一直出现小幅度波动,训练集和验证集损失值曲线有较大的波动,验证集损失值曲线发散,出现过拟合现象。T-SE-VGG16(uncut)模型在训练集和测试集的准确率一直出现小幅度波动,训练集损失值曲线出现小幅度波动,验证集损失值曲线发散,出现过拟合现象。VGG16模型在训练集和测试集的准确率有较大幅度波动,损失值曲线有小幅度的波动,模型没有收敛。

T-VGG16模型和T-SE-VGG16(uncut)模型均出现过拟合现象,出现过拟合现象的原因包括数据集大小和模型复杂度过高。本文使用的是数据增强以后的训练集,但是对于需要依赖大量数据样本的深度学习模型,本文数据集仍是小样本数据集。T-VGG16模型和T-SE-VGG16(uncut)模型的输出模块均为三层全连接层,包含了大量的训练参数,增加了模型复杂度。所提T-SE-VGG16模型通过对原模型的三层全连接层进行两层的删减,大量减少了训练参数量,降低了模型复杂度,结合迁移学习以后,对于小样本数据集,也能够很好地拟合数据。

实验最终获得的各模型识别准确率以及训练时间如表3所示。根据实验结果,对微型动物识别效果从高到低排序是:T-SE-VGG16、T-VGG16、T-SE-VGG16(uncut)、VGG16。训练一个轮次所花费时间由短到长排序是:T-SE-VGG16、T-VGG16、T-SE-VGG16(uncut)、VGG16。可以看出所提T-SE-VGG16模型具有最高的准确率,并且只需要最少的训练时间。

表3 各模型性能对比

Table 3 Comparison of performance of each model

Network	Accuracy / %	Time / s
VGG16	96.53	354
T-VGG16	97.26	76
T-SE-VGG16(uncut)	96.53	95
T-SE-VGG16	98.21	70

准确率反映了模型的整体分类性能,在多分类任务中,还使用精确率(precision)、召回率(recall)、精确率与召回率的调和均值(F1-score)作为模型对每个类别识别效果的评价标准。精确率(P)、召回率(R)、调和均值(F_1)分别定义为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (4)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (5)$$

$$F_1 = \frac{2 \times P \times R}{P + R}, \quad (6)$$

式中: N_{TP} 为被预测为正样本且实际也为正样本的数量; N_{FP} 为被预测为正样本而实际为负样本的数量; N_{FN} 为被预测为负样本而实际为正样本的数量。精确率表示预测为正的样本中实际为正样本的概率,召回率表示实际为正的样本中预测为正样本的概率,调和均值综合考虑精确率和召回率。得出的各个模型对各个类别的精确率、召回率、调和均值分别如表4~6所示。从表中可以看出,T-SE-VGG16模型对4类微型动物图像的精确率高于其他模型,对3类微型动物图像的召回率高于其他模型,对4类微型动物图像的调和均值高于其他模型,是所有模型中效果最显著的。

表4 各模型的精确率

Table 4 Precision of each model

Micro-animal	T-SE-VGG16	T-VGG16	T-SE-VGG16 (uncut)	VGG16
Rotifer	0.976	0.975	0.976	0.990
Euplotes	0.989	0.947	0.977	0.988
Peranema trichophonrum	0.990	0.979	0.989	0.916
Vorticella	1.000	0.993	0.986	0.986
Litonotus	0.947	0.958	0.894	0.973
Nematode	1.000	1.000	0.962	0.938

表5 各模型的召回率

Table 5 Recall of each model

Micro-animal	T-SE-VGG16	T-VGG16	T-SE-VGG16 (uncut)	VGG16
Rotifer	0.990	0.985	0.990	0.975
Euplotes	0.978	0.994	0.956	0.911
Peranema trichophonrum	0.975	0.940	0.915	0.990
Vorticella	0.986	1.000	1.000	0.986
Litonotus	0.993	0.958	0.993	0.986
Nematode	0.963	0.951	0.938	0.926

表 6 各模型的调和均值
Table 6 F1-score of each model

Micro-animal	T-SE-VGG16	T-VGG16	T-SE-VGG16 (uncut)	VGG16
Rotifer	0.983	0.980	0.983	0.982
Euplotes	0.983	0.975	0.966	0.948
Peranema trichophonrum	0.982	0.959	0.951	0.952
Vorticella	0.993	0.996	0.993	0.986
Litonotus	0.970	0.958	0.941	0.980
Nematode	0.981	0.975	0.950	0.932

综上,所提 T-SE-VGG16 模型相比其他模型具有更好的分类效果,验证了所提方法在污水活性污泥中微型动物分类任务的有效性。

4 结 论

使用深度卷积神经网络对 6 类常见的污水处理系统活性污泥中微型动物图像进行识别分类。针对图像数量少的问题,使用数据增强方法扩充数据集。在 VGG16 模型的基础上,添加注意力机制模块(SE-Net block)和调整输出模块对模型进行改进,结合迁移学习方法训练模型。实验结果表明:在数据增强数据集的训练下,改进后的模型 T-SE-VGG16 能够有效地对 6 种微型动物进行分类,识别准确率、精确率、召回率、调和均值指标优于改进前的模型;模型训练时间最短,收敛速度最快,鲁棒性强,验证了所提方法的有效性和可靠性。所提方法将深度学习运用到活性污泥中微型动物识别中,实现了端到端的微型动物分类,从而避免了耗时费力的人工特征的设计,为微型动物分类提供了一个新的思路。

参 考 文 献

- [1] 端正花,潘留明,陈晓欧,等. 低温下活性污泥膨胀的微生物群落结构研究[J]. 环境科学, 2016, 37(3): 1070-1074.
Duan Z H, Pan L M, Chen X O, et al. Changes of microbial community structure in activated sludge bulking at low temperature[J]. Environmental Science, 2016, 37(3): 1070-1074.
- [2] 陈奔. 活性污泥异质性识别、微生物衰退/功能分布及其应用原理[D]. 广州: 华南理工大学, 2019.
Chen B. Heterogeneity identification of activated sludge, distribution of microbial function and their application principle[D]. Guangzhou: South China University of Technology, 2019.
- [3] 张晓宁. 原后生动物在生活污水处理中的指示作用[J]. 广东化工, 2010, 37(11): 119-120.
Zhang X N. Indicative function of protozoan and metazoan in sewage treatment[J]. Guangdong Chemical Industry, 2010, 37(11): 119-120.
- [4] Li C, Wang K, Xu N. A survey for the applications of content-based microscopic image analysis in microorganism classification domains[J]. Artificial Intelligence Review, 2019, 51(4): 577-646.
- [5] Ginoris Y P, Amaral A L, Nicolau A, et al. Development of an image analysis procedure for identifying protozoa and metazoa typical of activated sludge system[J]. Water Research, 2007, 41(12): 2581-2589.
- [6] Ginoris Y P, Amaral A L, Nicolau A, et al. Recognition of protozoa and metazoa using image analysis tools, discriminant analysis, neural networks and decision trees [J]. Analytica Chimica Acta, 2007, 595(1/2): 160-169.
- [7] 刘俊. BP 神经网络在水中微生物识别系统的应用[D]. 昆明: 云南大学, 2012.
Liu J. Application of BP neural network in the identification system of microorganisms in water [D]. Kunming: Yunnan University, 2012.
- [8] 陈瑶. 活性污泥中常见原后生动物图像识别系统[D]. 昆明: 云南大学, 2011.
Chen Y. Image recognition system for common protozoan and Metazoan in activated sludge[D]. Kunming: Yunnan University, 2011.
- [9] Wang Y H, Tao S X, Chen J. Image fusion technology application in water quality monitoring based on digital microscopic[J]. Applied Mechanics and Materials, 2013, 295/296/297/298: 909-914.
- [10] Wang Y H. Research on segmentation of protozoan and metazoan image in microscopic examination of activated sludge[J]. Applied Mechanics and Materials, 2013: 367-370.
- [11] Xu H, Li C, Rahaman M M, et al. An enhanced framework of generative adversarial networks (EF-GANs) for environmental microorganism image augmentation with limited rotation-invariant training data[J]. IEEE Access, 2020, 8: 187455-187469.
- [12] Zhao P, Li C, Rahaman M M, et al. A comparison of deep learning classification methods on small-scale image data set: from convolutional neural networks to visual transformers[EB/OL]. (2021-06-16)[2021-05-06]. <https://arxiv.org/abs/2107.07699>.
- [13] Liang C M, Lai C C, Wang S H, et al. Environmental microorganism classification using optimized deep learning model[J]. Environmental Science and Pollution Research International, 2021, 28(24): 31920-31932.
- [14] Kulwa F, Li C, Zhang J H, et al. A new pairwise deep learning feature for environmental microorganism image analysis[J]. Environmental Science and Pollution Research, 2022: 1-18.

- [15] Li C, Xu N, Jiang T, et al. A brief review for content-based microorganism image analysis using classical and deep neural networks[M]//Pietka E, Badura P, Kawa J, et al. Information technology in biomedicine. Advances in intelligent systems and computing. Cham: Springer, 2019, 762: 3-14.
- [16] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6: 60.
- [17] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [18] 张宸嘉, 朱磊, 俞璐. 卷积神经网络中的注意力机制综述[J]. 计算机工程与应用, 2021, 57(20): 64-72.
Zhang C J, Zhu L, Yu L. Review of attention mechanism in convolutional neural networks[J]. Computer Engineering and Applications, 2021, 57(20): 64-72.
- [19] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-06-04]. <https://arxiv.org/abs/1409.1556>.
- [20] 杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12): 1474-1489.
Yang Z Z, Kuang N, Fan L, et al. Review of image classification algorithms based on convolutional neural networks[J]. Journal of Signal Processing, 2018, 34(12): 1474-1489.
- [21] 滕文秀, 温小荣, 王妮, 等. 基于深度迁移学习的无人机高分影像树种分类与制图[J]. 激光与光电子学进展, 2019, 56(7): 072801.
Teng W X, Wen X R, Wang N, et al. Tree species classification and mapping based on deep transfer learning with unmanned aerial vehicle high resolution images[J]. Laser & Optoelectronics Progress, 2019, 56(7): 072801.
- [22] 邢永鑫, 吴碧巧, 吴松平, 等. 基于卷积神经网络和迁移学习的奶牛个体识别[J]. 激光与光电子学进展, 2021, 58(16): 1628002.
Xing Y X, Wu B Q, Wu S P, et al. Individual cow recognition based on convolution neural network and transfer learning[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1628002.