

吴婕,张海翔. 基于特征增强的小样本图像分类算法研究[J]. 智能计算机与应用, 2024, 14(7): 37-42. DOI: 10.20169/j.issn.2095-2163.240705

# 基于特征增强的小样本图像分类算法研究

吴婕, 张海翔

(浙江理工大学 计算机科学与技术学院, 杭州 310018)

**摘要:** 由于小样本学习 (Few-Shot Learning, FSL) 中标记样本数量有限, 为了避免过拟合, 主干网络通常只能选择深度较浅、宽度较窄的轻量级网络, 然而轻量级主干网络只能对图像进行浅层特征提取, 特征提取的充分性并不足够。因此, 本文提出了两种通过丰富特征提取的多样性来进行特征增强的方法: 方法一, 时域特征分析和频域特征分析相结合的特征分析方法; 方法二, 利用监督学习和无监督学习并存的学习方法。本文提出的这两种特征增强方法在小样本学习中的 5-way 1-shot 设置下, 分类准确率分别提高了 0.27% 和 1.41%; 在 5-way 5-shot 设置下, 分类准确率分别提高了 5.72% 和 5.02%。

**关键词:** 小样本学习; 特征增强; 频域特征分析; 无监督学习

中图分类号: TP273

文献标志码: A

文章编号: 2095-2163(2024)07-0037-06

## Feature enhancement based algorithm for few-shot image classification

WU Jie, ZHANG Haixiang

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

**Abstract:** Due to the limited number of labeled samples in Few-Shot Learning (FSL), in order to avoid overfitting, the backbone network usually has to choose a lightweight network with shallow depth and narrow width. However, the lightweight backbone network can only extract shallow features of the image, and the adequacy of feature extraction is not enough. Therefore, this paper proposes two methods for feature enhancement by enriching the diversity of feature extraction. Method one, the feature analysis method combining time domain feature analysis and frequency domain feature analysis, method two, the learning method using supervised learning and unsupervised learning coexist. The two feature enhancement methods proposed in this paper improve the classification accuracy by 0.27% and 1.41% respectively in the 5-way 1-shot setting in few-shot learning, and 5.72% and 5.02% respectively in the 5-way 5-shot setting.

**Key words:** few-shot learning; feature enhancement; frequency domain feature analysis; unsupervised learning

## 0 引言

随着深度学习技术和硬件能力不断提高, 人工智能在很多领域都取得了显著的成就, 如: 在农业领域, 深度学习技术可以实现智能化种植和病虫害监测, 提高农业生产效率, 减少农药的使用量<sup>[1]</sup>; 在金融领域, 深度学习技术可以实现风险管理、信用评估和欺诈检测, 保障金融交易的安全和可靠<sup>[2]</sup>; 在无人驾驶领域, 深度学习技术能够实现自主导航和安全驾驶<sup>[3]</sup>。然而, 随着深度学习的广泛使用, 其缺

点也逐渐暴露出来, 即一个优秀的模型在很大程度上需要海量的训练数据作为支撑, 但在有些领域中, 由于数据获取涉及到安全、伦理、资源和成本等原因, 获取标记数据的成本昂贵、困难, 甚至不可能获得足够的标记数据样本<sup>[4-6]</sup>。基于少量样本训练大型模型时, 通常会出现严重的过拟合问题, 导致训练策略精度高, 测试策略精度却低, 在这种情况下, 传统的深度学习算法失去了神奇的性能<sup>[7]</sup>。相比于需要大量训练数据的深度学习网络, 少量样本足以让人类快速识别新物体, 如: 孩童只需学习一些图

**基金项目:** 国家自然科学基金(61672466, 62011530130); 浙江省自然科学基金(LSZ19F010001); 浙江省重点研发计划项目(2020C03060)。

**作者简介:** 吴婕(1998-), 女, 硕士研究生, 主要研究方向: 深度学习, 计算机视觉, 小样本图像分类; 张海翔(1973-), 男, 博士, 副教授, 主要研究方向: 三维重建, 人体姿态估计, 三维形状生成。

收稿日期: 2023-04-18

哈尔滨工业大学主办 ◆ 学术研究与应用

片就可以认识“折耳猫”和“狸花猫”。因此,研究人员模仿人类快速学习的能力,提出了小样本学习。

与传统网络不同,小样本学习模型通过输入的一张或几张标记图像就能训练出性能良好的分类器,以训练时采样5个类别,每个类别1个样本(5-way 1-shot)设置下的小样本学习为例如图1所示,模型通过学习支持集中给定的5个类别,分别是鸟、蛙、鹤、船、望远镜,每个类别有1个样本,总共5个样本,就能判断出查询集中给出的不同于支持集中样本的新样本的类别,模型将新样本分别预测为鸟和船,与事实相符。

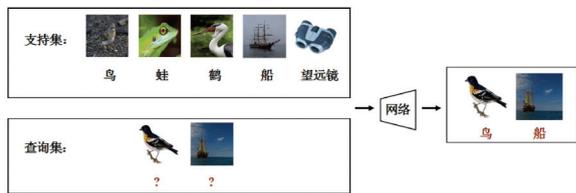


图1 小样本学习示例(5-way 1-shot)

Fig. 1 Example of few-shot learning as an example(5-way 1-shot)

小样本学习的出现,成功地将人工智能带入了小样本学习的时代,深度学习任务不再依赖于大量的数据集,大大降低了数据获取和训练的开销<sup>[8]</sup>。

本文主要针对小样本图像分类中的特征增强方法进行了一系列研究,对小样本学习中存在的特征提取不充分问题,在基线 DPGN (Distribution Propagation Graph Network) 上进行了以下两个方面的改进:增加特征提取的广度,丰富特征提取的方式,并在 CUB-200-2011 数据集上进行模型性能测试。

## 1 算法描述

### 1.1 基于离散小波变换的频域特征提取

在图像处理和计算机视觉中,常常使用时域和频域表示法进行图像处理和特征提取,例如:在时域中,使用图像卷积进行边缘检测和特征提取;在频域中,使用傅里叶变换或小波变换进行频域滤波和频域特征提取。频域分析法是从频率的角度分析图像,能揭示时域角度忽略的问题,优点是可以把时域信号拆分为不同频率的分量,从而深入挖掘信号的本质,了解信号的组成成分,以更好地利用信号<sup>[9]</sup>;其次,可以去噪或选择重要的频率分量。

常见的频域变换方法包括傅里叶变换、小波变换等。傅里叶变换可以将时域信号分解成一系列正弦和余弦函数的和,这些函数代表不同的频率成分,这些频率成分的振幅和相位可以描述信号在频域上

的特性,如频率成分的大小、频率的分布等<sup>[10]</sup>。小波变换可以用于将图像分解成不同尺度的小波基函数的线性组合,通过将原始图像分解成不同的分辨率和频率来描述其特征的一种方法,因此可以用于提取信号或图像的特征,例如边缘、纹理等<sup>[11-12]</sup>。

与传统的傅里叶分析相比,小波变换能够将图像分解为不同尺度的小波系数,这种多分辨率分析能够更好地捕捉图像的局部特征和全局特征<sup>[13]</sup>;而傅里叶分析使用固定的正弦和余弦基函数,只能提供频域上的全局特征,不能对图像进行多尺度分析<sup>[14]</sup>。同时,小波变换对于图像中的局部噪声和干扰具有较好的鲁棒性,而傅里叶分析则对于这些干扰容易出现频谱泄漏现象,从而影响分析结果的精度<sup>[15]</sup>。小波变换算法的计算量比傅里叶分析算法小,具有较高的计算效率。

小波变换的意义在于可以提供一种多分辨率的分析方法,能够捕捉图像的局部特征和全局特征,并且具有较好的局部性和可变性<sup>[16]</sup>。因此,本文采用基于离散小波变换的频域分析方法来提取图像的频谱特征,如图2所示。

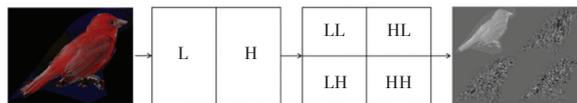


图2 本文中的二维离散小波变换方法示例图

Fig. 2 2D discrete wavelet transform method in this paper

对图像的处理流程如下:

(1) 对图像进行一次按行低通滤波和一次按行高通滤波,即一维小波变换。低通滤波允许低频信息通过,生成低频信息,低频信息对应于图像的平滑区域,包含图像的大致形状和轮廓,可以通过求均值来得到;高通滤波允许高频信息通过,生成高频信息,高频信息对应于图像的细节区域,包含了图像的局部特征和变化,可以通过求差值得到;

(2) 对图像进行二维小波变换,对低频和高频信息分别做一次按列低通滤波和一次按列高通滤波,共得到4个子带:水平低频,垂直低频(LL)、水平低频,垂直高频(LH)、水平高频,垂直低频(HL)、水平高频,垂直高频(HH)。其中,LL频带保留了原始图像的低频信息和内容信息,LH频带和HL频带分别保留了图像水平方向和垂直方向的高频信息,而HH频带则保留了图像对角线方向的高频信息;

(3) 为了利用不同子带中的信息,如纹理、颜色、结构、形状等进行频域特征分析,本文将小波变换得到的4个大小为原图1/4的子带按图2所示顺

序进行拼接, 拼接后的图片为原图大小。

在深度学习中, 有时会利用辅助训练分支来提升分类精度, 如 EPNet (Embedding Propagation Network) 网络。EPNet 在小样本分类主路之外, 还添加了旋转预测辅助训练分支如图 3 所示, 该旋转预测分支, 在 5-way 1-shot 设置下将模型分类准确率提高了 0.5%。因此, 本文提出增加一条基于离散小波变换的频域特征分析辅助训练分支 (简称为“频域分支”), 离散小波变换频域分析的模型如图 4 (b) 所示频域分支与时域分支, 即基线提出的实例传播所在支路是并联的关系, 首先通过二维离散小波变换得到离散小波变换图像数据, 并将其输入主干网络, 得到图像的频谱特征, 进而进行分类辅助训练。在添加频域分支之后, 模型分类准确率在 5-way 1-shot 设置下提高了 0.27%, 在 5-way 5-shot 设置下提高了 5.72%。

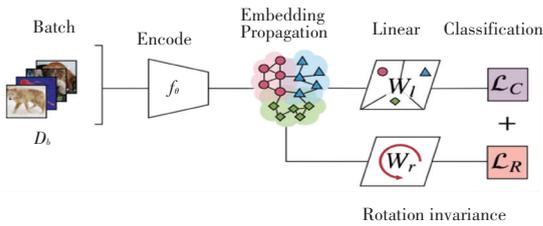
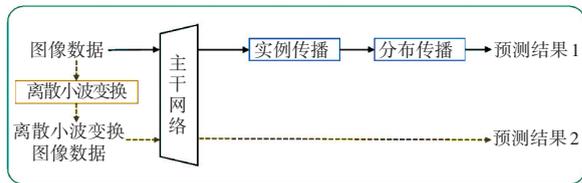


图 3 EPNet 中的旋转预测辅助训练分支示意图<sup>[12]</sup>

Fig. 3 Rotation prediction auxiliary training branch in EPNet<sup>[12]</sup>



(a) 基线



(b) 基线+频域分析

图 4 添加了离散小波变换频域分析的模型与基线

Fig. 4 Compares the baseline+frequency-domain-analysis model with baseline

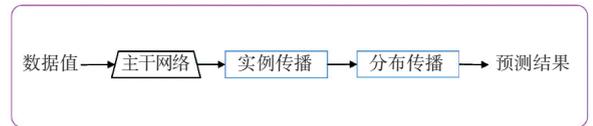
### 1.2 基于 k-means 聚类无监督学习

无监督 k-means 聚类算法是一种常见的基于距离度量的算法, 其无需图像标签, 而是直接从数据中提取信息, 通过度量样本间相似性, 将数据聚集成给定量的簇, 利用簇中心代表该簇的特征, 并使簇内样本相似度高且簇间样本相似度最低, 来实现对特征向量的聚类<sup>[17]</sup>。使用 k-means 聚类算法不仅

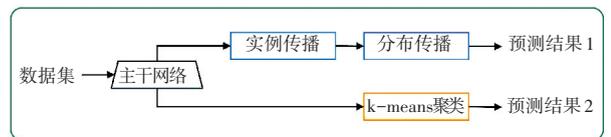
可以实现数据降维, 还可以减少数据中的噪声和冗余信息, 提取出对于分类任务最为关键的特征, 进一步提高模型训练的效率。本文实现 k-means 聚类步骤如下:

- (1) 设置聚类数目  $k = 5$ , 即需要将数据分为 5 类;
- (2) 使用 Arthur 和 Vassilvitskii 提出的 kmeans+中心初始化方法, 初始化 5 个聚类中心<sup>[18]</sup>;
- (3) 计算每个样本到每个聚类中心的欧几里得距离;
- (4) 将每个样本分配到距离其最近的聚类中心所在的簇;
- (5) 对于每个簇, 取该簇内所有样本的平均值作为新的聚类中心;
- (6) 重复执行步骤(3)至(5), 直到达到预设迭代循环次数 10 次, 或者精确度即两次簇中心的误差的差值  $\epsilon = 1.0$  为止;
- (7) k-means 聚类的最终结果是得到 5 个簇, 每个簇代表一个类别, 一个簇内的样本被预测为同一类别。

本文在基线的后处理中添加了一条基于 k-means 聚类的无监督学习分支 (简称为“无监督分支”) 如图 5 所示, 模型在基线提出的监督分布传播支路中依次通过实例传播和分布传播, 利用图像标签进行监督学习, 在无监督分支中通过无监督学习, 挖掘图像数据内在的结构, 并有效增加了特征提取方式的多样化。在添加无监督分支后, 模型分类准确率在 5-way 1-shot 设置下提高了 1.41%, 在 5-way 5-shot 设置下提高了 5.02%。



(a) 基线



(b) 基线+无监督学习

图 5 添加无监督 k-means 聚类的基线模型与基线的对比

Fig. 5 Compares the baseline+unsupervised-learning model with baseline

### 1.3 目标函数设计

#### 1.3.1 频域损失

在频域分支中, 测试样本的预测类别概率计算,

在频域分支中模型将  $x_i$  预测为  $y_j$  的概率  $P^{\text{dwt}}(y_j | x_i)$ , 公式(1):

$$P^{\text{dwt}}(y_j | x_i) = \text{Softmax}\left(\sum_{j=1}^{KN} \text{dwt}(x_i) \cdot \text{onetot}(y_j)\right) \quad (1)$$

其中,  $x_i$  是测试样本;  $y_j$  是支持集中第  $j$  个样本的标签;  $K$  是类别数量;  $N$  是每个类别的样本数量;  $\text{dwt}(x_i)$  表示频域分支中模型对第  $i$  个查询样本的预测标签。

频域分支中的频域损失计算, 公式(2):

$$L^{\text{dwt}} = L_{CE}(P^{\text{dwt}}(y_j | x_i), y_j) \quad (2)$$

其中,  $L_{CE}$  为交叉熵损失函数。

### 1.3.2 无监督损失

无监督分支中的无监督损失计算, 公式(3):

$$L^{\text{kmeans}} = \sum_{j=1}^{KN} (1 - \text{equal}(\text{kmeans}(x_i), y_j)) \quad (3)$$

其中,  $\text{equal}(\cdot)$  表示判断两个元素是否相等, 当  $\text{kmeans}(x_i) = y_j$  时输出 1, 否则输出 0。

## 2 实验设计

标准的小样本图像分类任务中有两个数据集: 训练集  $D_{\text{base}} = \{(x_i, y_i), y_i \in C_{\text{base}}\}$  和测试集  $D_{\text{novel}} = \{(x_i, y_i), y_i \in C_{\text{novel}}\}$ , 其中  $C_{\text{base}}$  和  $C_{\text{novel}}$  分别代表训练类别和测试类别, 两者不重叠即  $C_{\text{base}} \cap C_{\text{novel}} = \emptyset$ 。小样本图像分类的训练和测试是由很多个小任务(episode)构成的, 每个 episode 都由随机采样的  $K$  个类别组成, 每个类别由  $N$  个标记图像和  $U$  个未标记图像组成, 即  $K$ -way  $N$ -shot 任务。标记图像组成支持集  $S = \{(x_i, y_i)\}_{j=1}^{KN}$ , 未标记图像组成查询集  $Q = \{(x_i, y_i)\}_{j=1}^{KU}$ , 两者不重叠即  $S \cap Q = \emptyset$ 。

以 5-way 1-shot(即  $K = 5, N = 1$ ) 任务为例:

(1)按类别划分训练集  $D_{\text{base}}$  和测试集  $D_{\text{novel}}$ ;

(2)训练集  $D_{\text{base}}$  采样 5 个类别, 每个类别采样 1 个样本作为标记图像, 组成支持集  $S$ ; 这 5 个类别再采样  $U$  个样本作为未标记图像, 组成查询集  $Q$  (其中  $U$  可按自己的需求设置, 如 1 或 15 等, 在本文取  $U = 1$ );

模型学习支持集  $S$  和查询集  $Q$  中图像的特征, 并预测查询集  $Q$  中图像的分类标签, 将预测标签和真实标签进行损失计算并将损失反向传播。

(3)重复步骤(2), 直至设定的 episode 数;

(4)测试集  $D_{\text{novel}}$  采样 5 个类别, 每个类别采样 1 个样本作为标记图像, 组成支持集  $S'$ ; 这 5 个类别再采样  $U'$  个样本作为未标记图像, 组成查询集  $Q'$ ,

用于测试模型对查询样本类别的预测准确率 (accuracy,  $Acc$ ) (其中  $U'$  可按自己的需求设置, 如 1 或 15 等, 在本文中取  $U' = 1$ )。

(5)重复步骤(4)直至设定的 episode' 数;

(6)重复步骤(2)~(5), 直至设定的 epoch 数。

为了保证本文提出的小样本分类算法与基线的小样本分类算法有可比性, 本文中的数据集和实验参数的设置与基线保持一致。

### 2.1 数据集

CUB-200-2011 数据集是一个标准的小样本图像分类的数据集, 相比于其他常见的图像分类数据集如 ImageNet, CUB-200-2011 数据集中每个类别的样本数量都非常少, 使得成为了研究小样本学习问题的经典数据集之一。该数据集划分为 100 个基类, 其中验证类有 50 个类别, 5 994 张图像, 测试类同样有 50 个类别, 5 794 张图像, 总共 11 788 张图像。此外, CUB-200-2011 数据集涵盖了 200 种不同的鸟类, 每个种类有大约 60 张不同角度和姿态下的图片, 这些图片是由世界各地的观鸟爱好者和专业摄影师拍摄的, 因此包含了多种背景和光线条件下的鸟类图像。在 CUB-200-2011 数据集中, 每个图像都被注释了鸟类名称、位置、轮廓和部分标记, 本文使用了鸟类名称和轮廓标记信息。

### 2.2 主干网络

采用 ResNet12 作为主干网络。主干网络的最后一个特征通过全局平均池化处理后, 经过带有批归一化的全连接层, 得到一个 128 维的实例特征作为主干网络的最终输出。

### 2.3 评价指标

以准确率  $Acc$  作为评价指标。在小样本学习标准数据集 CUB-200-2011 上, 随机抽取 10 000 个任务分别对 5-way 1-shot 和 5-way 5-shot 设置计算  $Acc$ 。

## 3 实验设计

### 3.1 基于离散小波变换的频域特征提取

为了证明基于离散小波变换频域特征分析方法的有效性, 本文基于基线进行了消融实验, 实验结果见表 1。由表 1 中, 可以看出添加小波分析后的模型的准确率比不添加时的有提升, 在 5-way 1-shot 设置下有 0.27% 的提升, 在 5-way 5-shot 设置下有 5.72% 的提升, 证明通过添加频域特征辅助训练, 可以获得更高的准确率, 当给定训练样本数量更多时, 提升更为显著。

表1 频域分析对模型准确率的影响

Table 1 Influence of frequency domain analysis on accuracy %

模型	CUB-200-2011	
	5-way 1-shot	5-way 5-shot
基线	75.71	83.21 *
基线+dwt	<b>75.98</b>	<b>88.93</b>

注: \* 表示是基于论文源码复现的结果。

### 3.2 基于k-means聚类无监督学习

为了证明基于无监督k-means聚类方法的有效性,本文以5-way 1-shot和5-way 5-shot两种设置在CUB-200-2011数据集上进行了消融实验,实验结果见表2,可以看出添加k-means聚类后的模型的准确率优于不添加的准确率,在5-way 1-shot设置下有1.41%的提升,在5-way 5-shot设置下有5.02%的提升。由于在5-way 5-shot设置下的训练样本是5-way 1-shot的5倍,聚类算法能够获得更多的数据信息,通过更全面的计算得到更优的聚类中心,从而在分类准确率上得到了更明显的提升,所以5-way 5-shot设置下模型精度的提高是5-way 1-shot设置下的3.5倍。

表2 无监督学习对模型的准确率的影响

Table 2 Impact of unsupervised learning on accuracy %

模型	CUB-200-2011	
	5-way 1-shot	5-way 5-shot
基线	75.71	83.21 *
基线+K-means	<b>77.12</b>	<b>88.23</b>

\* 表示是基于论文源码复现的结果。

## 4 结束语

### 4.1 工作总结

作为机器学习领域中的一个里程碑,深度学习在诸多任务上都取得了惊人的成就。但深度神经网络模型的参数较多,在训练时需要大量的有标签数据,在很多情况下是不现实的。因此,利用少量带标签的数据来训练高效的深度学习模型,对于学术界和工业界而言是非常重要的。在这种情况下,小样本学习成为了一个备受关注的研究领域。小样本学习旨在通过仅使用极少量的有标签数据,训练出具有良好泛化能力的深度学习模型<sup>[19]</sup>。目前有许多有效的小样本学习方法和技术,包括基于元学习的方法、迁移学习、生成模型等<sup>[20]</sup>。本文在基线的基础上,提出了具有针对性的特征增强的算法改进技巧,并在小样本学习问题的经典数据集CUB-200-2011上,对所提出的技巧的有效性进行了实验

证。

本文主要针对特征提取的广度以及特征提取的方式,提出了以下两点技巧:

(1)为了扩大特征提取的广度,本文提出了基于离散小波变换的频域特征提取方法。本文通过对图像进行二维离散小波变换,得到4个子带,通过分析这4个子带来获得图像的频域特征。在5-way 1-shot设置下,此方法将模型的准确率提高了0.27%,在5-way 5-shot设置下,模型的准确率提高了5.72%。

(2)为了丰富特征提取的方式,本文提出同时利用监督分类学习和无监督聚类学习,增加特征提取方式的多样性。监督学习中通过训练数据的标签信息来指导网络的学习,让神经网络有明确的学习目标;无监督学习中通过k-means聚类对数据本身的学习来发现数据中的模式和结构,发掘数据中更多的信息,提高泛化能力。在5-way 1-shot设置下,此方法将模型的准确率提高了1.41%,在5-way 5-shot设置下,模型的准确率提高了5.02%。

### 4.2 未来展望

虽然本文提出的算法改进技巧使模型在基线上得到了一定的提升,但仍然存在一些不足,例如特征增强后不可避免地增加了模型的参数量和计算量。此外,本文仅基于单个基线对所提出方法进行验证,对于算法的泛化能力和适用性需进一步的检验和探究,对于未来的研究可以从以下两个方面展开:

(1)利用更简单的模型去逼近复杂模型的性能,如利用模型剪枝、知识蒸馏等方法。在对分类准确率没有较大影响的情况下,有效降低模型参数量,减轻硬件计算量,提高模型的效率和可用性,使得算法更易于在实际应用中落地;

(2)在更多的模型上验证本文提出的算法,更全面地评估算法的性能和泛化能力,有助于发现算法的局限性和改进方向。

在未来的研究中不断发现新的研究方向,提出更多的改进,以推动小样本分类领域的发展,推进小样本分类方法的落地。

## 参考文献

- [1] XING S, LEE M, LEE K. Citrus pests and diseases recognition model using weakly dense connected convolution network [J]. Sensors, 2019, 19(14): 3195.
- [2] XU R Z, HE M K. Application of deep learning neural network in online supply chain financial credit risk assessment [C]// Proceedings of 2020 International Conference on Computer

- Information and Big Data Applications (CIBDA). IEEE, 2020: 224-232.
- [3] WANG J, LIU J, KATO N. Networking and communications in autonomous driving: A survey[J]. IEEE Communications Surveys and Tutorials, 2018, 21(2): 1243-1274.
- [4] 张智军,王倩,席岩,等. 面向媒体融合的深度学习教育数据集研究[J]. 广播电视信息, 2017(10):5.
- [5] 马云飞,郑旭东,赵冉,等. 深度学习的发生机制与多模态数据测评研究[J]. 远程教育杂志, 2022, 40(1):50-60.
- [6] 陈蓉蓉. 基于半监督 Tri-training 的迁移学习算法研究[D]. 大连: 辽宁师范大学, 2024.
- [7] 张健. 具备过拟合抑制的生成式对抗网络模型构建及遥感分类应用[D]. 银川: 北方民族大学, 2019.
- [8] 夏千涵,何胜煌,吴元清,等. 基于可学习记忆特征金字塔网络的小样本目标检测[J]. 计算机与现代化, 2023(12):7-13.
- [9] 高宏. 股票价格白噪声积分模型及时域和频域特性研究[J]. 当代经济,2019(9):31-33.
- [10] CERNA M, HARVEYA F. The fundamentals of FFT - based signal analysis and measurement [R]. Application Note 041, National Instruments, 2000.
- [11] 陈卓明. 基于多尺度分析的海洋石油机械零件表面缺陷分割[J]. 中国新技术新产品,2022(24):63-65.
- [12] 竺乐庆,张真,张培毅. 基于颜色直方图及双树复小波变换 (DTCWT)的昆虫图像识别[J]. 昆虫学报,2010,53(1):91-97.
- [13] 赵广超,肖斌,国闯,等. 小波分析理论与图像降噪处理[J]. 微型机与应用,2011,30(19):35-37.
- [14] SIFUZZAMAN M, RAFIQ M I, MOSTAFA Z. Application of wavelet transform and its advantages compared to Fourier transform [J].Journal of Physical Sciences ,2009(13):121-134.
- [15] 郭振涛,迟长春,武一. 基于 Blackman 自乘-卷积窗的 FFT 谐波检测算法[J]. 电测与仪表,2019,56(13):16-22.
- [16] 刘叙含. 基于图像压缩感知的信源信道联合编码系统研究[D]. 西安: 西北工业大学, 2015.
- [17] 亓潇. 基于 K 均值聚类的自动文摘系统研究[D]. 长春: 吉林大学, 2024.
- [18] ARTHUR D, VASSILVITSKII S. K-means++ the advantages of careful seeding[C]//Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. IEEE, 2007: 1027-1035.
- [19] LIU Y, ZHANG H, ZHANG W, et al. Few - shot image classification: Current status and research trends[J]. Electronics, 2022, 11(11): 1752.
- [20] SONG Y, WANG T, CAI P, et al. A comprehensive survey of few - shot learning: Evolution, applications, challenges, and opportunities[J]. ACM Computing Surveys, 2023, 55(13s): 1-40.