

多尺度特征融合注意力的轻量化遥感场景分类方法

张冬梅¹ 宋子涛²

ZHANG Dongmei SONG Zitao

摘要

针对目前常见的遥感影像场景分类卷积神经网络存在特征提取能力不足及模型参数量大的问题,提出一种多尺度特征融合注意力的轻量化遥感影像场景分类方法。将 Res2Net 网络作为基准模型,在 Res2Net 模块内嵌入改进的 CBAM 注意力模块进行优化,关注场景中的关键特征,提高全局特征和局部特征的表达能力;在 Res2Net 模块间插入深度可分离单元,增加不同尺度特征的连接和复用性,轻量化网络模型,提高运行效率。在 UCM 数据集上,所提方法的总分类精度方面达到 96.90%,相比基线方法提高 2.38%。实验表明,所提方法参数量较低,能有效提高场景分类的准确率。

关键词

场景分类;多尺度;特征融合;注意力机制

doi: 10.3969/j.issn.1672-9528.2024.10.006

0 引言

遥感影像场景分类的主要任务是根据人造卫星、无人机或其他飞行器收集地物信息的遥感图像内容,判断图像中的地物类别,如机场、农田、森林或港口等^[1],在城市规划^[2]、地质灾害监测^[3]、环境监测^[4]等方面具有广泛的应用。


多尺度特征表示在视觉任务中非常重要的^[5]。现有的遥感影像场景分类方法中,卷积神经网络(convolutional neural networks, CNN)因其具有强大的特征提取能力,在多尺度特征表征和检测性能上表现出巨大优势。近年来出现了大量的具有多尺度表示能力的骨干卷积神经网络,如 GoogLeNet^[6]、ResNet^[7]、DLA^[8]和 Res2Net^[9]等。GoogLeNet 使用不同内核大小的并行过滤器增强多尺度表示能力,但其不能覆盖大范围的感受野。ResNet 引入残差连接允许不同的卷积操作进行组合,产生多尺度特征。DLA 结合树结构的层使得网络获得更强的分层多尺度表示能力。Res2Net 将一组 3×3 的过滤器组替换为更小的过滤器组并将其以分层残差的方式进行连接,具有更强大的多尺度特征提取能力。由于遥感影像相较于普通图像存在图像信息复杂、数据标注困难、一些特殊场景中影像数据较少等问题,导致模型泛化能力和鲁棒性较差,检测难度较大。逯登科等人^[10]基于 ResNet50 与通道注意力,提取影像主要特征,提高分类精度。朱杰凡等人^[11]基于 ResNeXt 网络模型结合注意力机制,以优化后

支持向量机替换全连接层的模型,在整体不增加超参数的情况下优化了网络性能,但模型的复杂度提高。杨星等人^[12]基于 ResNet 通过迁移学习方法实现用少量样本完成场景分类,但分类精度有待提升。吕欢欢等人^[13]为降低网络参数,构建了深度可分离残差网络轻量化网络结构,但对于特征非常相似的类别,分类结果有待提高。

基于以上研究现状,在轻量化网络结构的前提下,为提升多尺度特征的表示能力,本文在 Res2Net 模型中引入注意力机制来增强模型对相似类别的特征,通过深度可分离网络连接 Res2Net 单元,整合网络层次的特征,提高检测精度,并在遥感影像的公开数据集上进行验证。

1 Res2Net

Res2Net 模块是一种简单而有效的多尺度处理方法,旨在细粒度级别表示多尺度特征。Res2Net 在 ResNet 的基础上提出,将输入特征从通道维度进行分组,每个分支单独卷积并分层叠加,通过增加分支数、改变不同分支的扩张率实现有效提取多尺度特征。其网络结构对比如图 1。



(a) 瓶颈网络

(b) Res2Net

图 1 瓶颈网络与 Res2Net 网络结构对比

1. 山西科技学院大数据与计算机科学学院 山西晋城 048000

2. 山西科技学院机电工程学院 山西晋城 048000

[基金项目] 山西科技学院校内科研基金项目(XKY002、XKY024)

图 1 (a) 为瓶颈结构是许多现代骨干 CNN 架构的基本构建块, 图 1 (b) 是 Res2Net 模块的结构。Res2Net 将瓶颈网络中一组 3×3 卷积核替换为一组较小的滤波器组, 先分组后, 再以类似残差的方式进行连接, 以增加尺度表示的输出特征, 进而增加模型的感受野, 在计算力相同的条件下获得更强的多尺度表征信息。在第一个 1×1 卷积后, 将输入特征 x 在通道维度平均分割成 s 个特征子集, 记为 x_i , $i \in \{1, 2, \dots, s\}$, 每一个特征子集 x_i 与输入特征 x 相比都有相同的空间大小, 但特征维度是其 $1/s$ 。除 x_1 , 每一个 x_i 都有一个对应的 3×3 卷积, 记为 $K_i()$, 用 y_i 表示 $K_i()$ 的输出。特征子集 x_i 加上前一个输出 $K_{i-1}()$ 输入到 $K_i()$ 中。为了在增加 s 的同时减少参数, 省略了 x_1 的 3×3 卷积。因此, y_i 可以写成:

$$y_i = \begin{cases} x_i, i=1 \\ K_i(x_i), i=2 \\ K_i(x_i + y_{i-1}), 2 < i \leq s \end{cases} \quad (1)$$

为了更好地融合不同尺度的信息, Res2Net 模块将所有特征子集按照通道维度依次拼接, 输入到 1×1 卷积中。分组卷积和拼接操作可以强制执行卷积, 有利于提取全局和局部特征。

2 本文研究方法

2.1 多尺度特征融合注意力的轻量化场景分类模型

本文提出的多尺度特征融合注意力的轻量化场景分类模型以 Res2Net 作为基本网络结构, 结合尺度大小改进 Res2Net 单元中的分层残差类连接, 结合改进的 CBAM (convolutional block attention module) 注意力模块优化 Res2Net 模块, 每个模块之间使用深度可分离卷积进行特征重用。对应的模型结构如图 2 所示。模型包含 5 个改进的 Re2Net 模块 $R_1 \sim R_5$, 4 个深度可分离卷积单元 $D_1 \sim D_4$, 3 个注意力机制 $A_1 \sim A_3$, 2 个标准卷积模块、1 个全局平均池化层 (GAP) 及 1 个分类输出层。




图 2 算法流程

2.2 改进的 Res2Net

为了增强全局特征和局部特征, 扩大提取特征的感受野, 本文将滤波器组 3×3 设计为一组包含 3×3 、 5×5 和 7×7 三个不同大小尺寸的卷积核。改进后的 ResNet 网络结构如图 3 所示。从图 3 可以看到, 随着分组后特征子集的并行层次增

加, 卷积核尺度增加。由于当前特征子集在进行卷积前融合了前面所有的特征子集, 故随着卷积核尺度的增加, 可以扩大模型的感受野, 更好地捕获输入数据的场景信息, 提高模型对输入数据的感知能力和表征能力。本文使用 5 个改进后的 Res2Net 模块, 记为 $R_1 \sim R_5$ 这 5 个单元。





图 3 改进后的 Res2Net 结构


2.3 引入深度可分离卷积

为增强特征在网络中的复用性, 确保不同网络层次的特征能够有效地传递和整合, 在 Res2Net 单元间增加卷积连接, 以增强网络对不同尺度和层次特征的表征能力。

标准卷积在计算过程中, 卷积层数众多, 会增加模型的复杂度和计算开销, 不适用于在算力及内存资源有限的设备上场景分类, 因此将标准卷积 (standard convolution, SC) [14] 替换为深度可分离卷积 (depthwise separable convolution, DSC), 在保证分类精度的同时使用轻量化网络结构。网络结构如图 4 所示。标准卷积的过程如图 4 (a) 所示。当其输入特征图为 $L \times W \times N$ 时, 假设有 M 个 $3 \times 3 \times N$ 的卷积核, 每个卷积核会与输入特征图的所有通道进行卷积运算, 并生成一个新的特征图。每个特征图对应着使用一个卷积核进行卷积运算的结果。



(a) 标准卷积流程



(b) 深度可分离卷积流程

图4 标准卷积和深度可分离卷积对比

标准卷积所用参数量 P_{sc} ，其公式为：

$$P_{sc} = 3 \times 3 \times N \times M = 9 \times N \times M \quad (2)$$

式中：3×3 是卷积核的大小， N 是输入通道数， M 是输出通道数。

深度可分离卷积过程如图4(b)所示，与标准卷积不同，将标准卷积分解为两个连续的部分^[15]，逐深度卷积 (Depthwise convolution) 用于提取空间特征，减少了计算负担和模型参数，成为后续轻量级 CNN^[16] 基本设计组件，逐点卷积 (Pointwise convolution) 用于提取信道特征。

逐深度卷积使用 N 个卷积核，每个卷积核大小为 $3 \times 3 \times 1$ ，能在空间维度上独立地对每个通道进行卷积运算，因此，逐深度卷积会生成 N 个新的特征图，每个特征图对应着输入特征图中的一个通道，保留了特征图更多的空间相关性；而逐点卷积用 M 个较小的 $1 \times 1 \times 1$ 的卷积核，每个卷积核都会与逐深度卷积生成的所有 N 个特征图进行卷积运算，终会生成 M 个新的特征图，每个特征图对应着一种新的特征组合。逐点卷积的作用是将所有通道的特征信息进行线性组合，生成最终的输出特征图。

深度可分离卷积的参数量 P_{dsc} 由逐深度卷积的参数量 P_{dc} 和逐点卷积的参数量 P_{pc} 构成，其公式为：

$$P_{dc} = 3 \times 3 \times N \quad (3)$$

$$P_{pc} = N \times M \quad (4)$$

$$\begin{aligned} P_{dsc} &= P_{dc} + P_{pc} = 3 \times 3 \times N + N \times M \\ &= 9 \times N + N \times M = N \times (9 + M) \end{aligned} \quad (5)$$

将深度可分离卷积参数量 P_{dsc} 与标准卷积参数量 P_{sc} 比较可得其比值 σ ，计算公式为：

$$\begin{aligned} \sigma &= P_{pc} / P_{sc} = \\ &= N \times (9 + M) / 9 \times N \times M \\ &= 9 + M / 9 \times M \end{aligned} \quad (6)$$

在模型搭建过程中，Res2Net 的输出通道 M 都比较大，故二者参数量比值 σ 远小于 1。

通过分析两种卷积的理论原理并比较其参数量，可知：深度可分离卷积在降低参数数量的同时能调整和恢复特征图的通道数，有效减少冗余信息，增强模型的特征提取能力。相比标准卷积操作，深度可分离卷积的参数数量和运算成本都较低，故将 Res2Net 单元间的卷积连接由标准卷积替换为深度可分离卷积。深度可分离卷积单元 ($D_1 \sim D_4$) 网络结构如图5所示。



图5 深度可分离卷积单元的结构

每个深度可分离卷积单元由深度可分离卷积、归一层 (batch normalization, BN) 和 ReLU (rectify linear units, ReLU) 激活函数构成。将深度可分离卷积层提取的特征图输入到归一化层标准化数据中，使得数据的分布相对稳定，加速模型学习，之后输入 ReLU 层对特征图进行非线性变换，增强模型表达能力，提高模型分类准确率。一个完整的深度可分离卷积单元不仅有效传递 Res2Net 单元的特征图，而且也加快了模型的推理速度。

2.4 改进 CBAM

考虑到遥感影像中，待分类物体的尺度存在差异性，为更好地融合不同尺度的全局语义关系，本文在 Res2Net 中引入卷积注意力机制^[17]，提高网络对关键特征的注意，优化网络的特征提取能力。

CBAM 是一种混合注意力模块，其中通道注意力子模块 (channel attention module, CAM) 能够更好地处理特征图通道的分配关系，空间注意力子模块 (spatial attention module, SAM) 使得模型更加关注遥感影像中的目标区域而忽略背景或其他干扰物的影像，提升模型的检测效果，两个子模块串行结合。为增加 CBAM 注意力机制的感受野，将原有空间注意力模块中的标准卷积替换为空洞卷积^[18]。改进后的 CBAM 注意力机制模块 ($A_1 \sim A_3$) 结构如图6所示。改进后的 CBAM 保留原有 CBAM 通道注意力模块结构，在通道模块中将特征图 F 经过全局平均池化和全局最大池、多层感知器后将获得的特征图逐元素相加，并通过 Sigmoid 激活函数得到权重系数 M_c ，将输入特征图 F 与该权重系数逐元素相乘生成空间注意力模块上需要的输入特征 F' 。改进空间注意力模块，将输入特征 F' 经过最大池化和平均池化后在通道维度上拼接，经过卷积核为 3、扩张率为 3 的空洞卷积进行降维，经过 Sigmoid 激活函数生成权重系数 M_s ，最后将该权重系数与输入 F' 相乘得到空间注意力模块

的输出特征图 F'' 。通过双注意力的串行结合，关注通道和空间维度重要的特征。




图 6 CBAM 网络结构

(注: F 表示输入特征图; F' 表示经通道注意力后的特征图; F'' 表示最终特征图; $\oplus$ 表示逐元相加操作; $\odot$ 表示 Sigmoid 激活函数操作; $\otimes$ 表示逐元相乘操作; H 和 W 分别表示特征图的高和宽; C 为通道数。)

3 实验结果与分析

3.1 数据集

实验采用遥感影像场景分类领域公开的数据集 UC Merced LandUse Dataset^[19] (以下简称 UCM 数据集)。UCM 数据集有 21 个类别, 每个类别包含 100 张 256×256 的图像, 共 2100 张。图 7 给出了数据集的部分图像。




图 7 数据集 UCM 示例样本

为了公平地评估本文提出的方法, 本文保持了与对照模型^[20] 相同的数据集划分比例。对于 UCM 数据集, 训练集比例设置为 80%, 其余的用于测试。

3.2 实验设置

(1) 训练参数

网络参数和设置如下: 为了缓解过拟合的问题, 提高模型的泛化能力和鲁棒性, 使用数据增强技术对数据进行预处理, 将训练数据进行采用随机 30° 旋转、水平翻转、垂直翻转, 提升模型的鲁棒性。

为适应网络模型的输入, 将图像的尺寸调整为 224×224 。因设备限制, 每批次样本输入量 (batch size) 设置为 16, 总训练次数 (epoch) 设置为 350 次。为加快模型收敛速度, 损失函数选择交叉熵损失来计算测试标签与真实标签的损失值, 并通过 Adam 优化器对模型进行优化, 学习率初始化为 0.001, 采用余弦退火策略作为优化器的调度器。

(2) 环境设置

在本项工作中, 所有实验在相同的环境配置下进行, 由于硬件资源限制, 本实验采用智星云高性能云主机, GPU 类型为 GeForce RTX 3080 (24 显存), CPU 核数为 12 核, 内存为 29 GB, 系统为 Windows10 LTSC 镜像。在 PyCharm 编辑器下使用 Python3.8.3、Tensorflow 2.4 和 cuda11 进行实验。

(3) 评价指标

在评估模型性能方面, 参考大多数遥感场景分类模型采用的标准, 计算出模型的总精度 (overall accuracy, OA)、混淆矩阵 (confusion matrix, CM) 和 Kappa 系数, 作为模型的综合评价指标。

(a) OA 定义为正确分类的样本数占测试集总样本数的比例, 反映了数据集总体的分类情况^[21]。

(b) CM 通过矩阵形式的表达, 其对角线元素表示该类别的分类正确率, 其余元素表示来自第 i 类的图像被误分为第 j 类的概率。

(c) Kappa 系数用于检验模型预测结果和实际分类结果是否一致, 基于混淆矩阵计算得, 该数值落在 $0 \sim 1$ 之间^[22]。

3.3 消融实验

使用 UCM 数据集对本文方法中改进 Res2Net 模块、添加深度可分离卷积单元以及改进 CBAM 注意力进行消融实验, 以验证各模块的有效性。基础方法是由 Res2Net 模块单独顺序连接而成的网络模型, 表 1 为消融实验的结果。

表 1 消融实验

方法	指标 / %		总参数量
	OA	Kappa	
基础方法	94.76	94.50	
基础方法 + 标准卷积	95.52	95.30	1 345 525
基础方法 + 深度可分离	95.57	95.34	825 845
基础方法 + 标准卷积 + 改进 CBAM	96.14	95.95	
基础方法 + 深度可分离 + 改进 CBAM	96.90	96.75	

从表 1 可以看出, 在 Res2Net 单元之间增加标准卷积模块或深度可分离卷积模块对网络提升效果基本相当, 但深度可分离模块在参数量方面优于标准卷积, 可轻量化网络结构。深度可分离和改进后的 CBAM 注意力模块都可提升网络效

果，但二者结合能达到最优。其主要原因是仅使用深度可分离卷积虽然在一定程度上能够减少参数数量、加快模型训练速度和降低计算成本，但在某些情况下可能无法充分关注关键特征，从而影响模型的性能表现。因此，为了弥补深度可分离卷积的一些局限性，引入改进后的 CBAM 结构可以在空间和通道维度上增强深度可分离卷积提取的特征，进一步提升模型的分类性能。

3.4 对比实验

(1) Res2Net 参数设置

为探究 Res2Net 模块中的卷积通道数对模型性能的影响，实验中将通道数取值为 64、128 和 256 进行评估模型的效果。实验结果如表 2 所示。

表 2 Res2Net 通道参数

Res2Net 通道数	指标 /%		运行总时间 /s	参数量
	OA	Kappa		
64	93.45	93.13	7984	192 517
128	94.58	94.31	9010	753 141
256	95.59	95.38	12 152	2 978 773

通过表 2 分析，Res2Net 通道数依次为 64、128 和 256 时，三种分类指标效果逐渐增加，但同时运行总时间和参数量也加大。通道数为 128 时的三种指标效果比通道数为 64 时超出 1.2%，运行总时间超出约 1100 s，参数量增加 2.9 倍；通道数为 256 时的三种指标效果比通道数为 128 时超出 1.1%，运行总时间超出 3100 s，参数量增加 3 倍。通过比较发现在分类指标效果增量基本相同的情况下，通道数 256 相较于 128 时，模型运行总时间和参数量增量较大，为均衡分类效果和模型轻量化，故通道数值取 128。

(2) 注意力机制的影响

为探究注意力机制对于模型性能的影响，在加入标准卷积连接的 Res2Net 模块基础上引入 CBAM 和改进后的 CBAM，并在 UCM 数据集上进行分类实验，结果如表 3 所示。

表 3 不同注意力放大的分类精度

方法	指标 /%	
	OA	Kappa
标准卷积	95.52	95.30
标准卷积+CBAM	95.76	95.55
标准卷积+改进 CBAM	96.14	95.95

结合表 3 可以看出，由标准卷积连接的 Res2Net 总分类精度达到 95.52%，Kappa 系数达到 95.30%，说明该模型在网络框架上适用于场景分类任务。引进 CBAM 和改进的

CBAM 注意力机制在分类总体精度上相比只加入标准卷积连接的模型效果分类效果都有提高，但改进后的 CBAM 注意力机制在特征融合和关注关键特征的方面更有效，总分类精度可达到 96.14%，Kappa 达到 95.95%，验证了改进后 CBAM 的有效性。

(3) 与其他方法对比

本文提出的方法与 UCM 数据集上最近的基线方法进行比较，如表 4 所示。

表 4 不同方法精度

方法	OA/%
文献 [20] 的基线方法	94.52
本文方法	96.90

文献 [20] 的基线方法使用 RepVGG 网络结合 ECA 通道注意力机制解决小样本数据受限问题，在 UCM 数据集上的分类总体准确率为 94.52%，本文在该数据集上分类总体准确率达到为 96.90%，提高了 2.38%，证明了本文方法在提高遥感影像场景分类准确率方面的有效性。

3.5 可视化分析

为进一步验证本文方法的分类性能，在 UCM 数据集上训练后的模型分类效果的混淆矩阵如图 8 所示。




图 8 在 UCM 数据集上的混淆矩阵

由图 8 所示的混淆矩阵可以得出，本文所提出的网络模型在 UCM 数据集上表现优异，且 14 类分类精度达到 100%，3 类达到 95%，1 类达到 90%，剩余两类达到 85% 左右，说明模型性能优越，能有效提取分类问题中的有效信息，明显提升卷积神经网络对遥感图像的分类能力。

4 结语

本文基于 Res2Net 模块改进网络模型提取多尺度场景语义特征，引进改进后的 CBAM 注意力模块，有效地提取影像的关键特征，并在 Res2Net 模块间引入深度可分离单元，增加多尺度特征的复用性。在 UCM 数据集上验证了

本文方法在遥感影像场景分类的有效性及模型的轻量化。但是往往实际的遥感影像中存在多个场景，如何保证在构建轻量化模型的同时实现多分类场景任务，是未来进一步研究的方向。

参考文献:

- [1]CHENG G, XIE X, HAN J, et al. Remote sensing image scene classification meets deep learning: challenges, methods, benchmarks, and opportunities[J].IEEE journal of selected topics in applied earth observations and remote sensing, 2020(13):3735-3756.
- [2]GONG C, HAN J, LU X. Remote sensing image scene classification: benchmark and state of the art[J].Proceedings of the IEEE,2017,105(10):1865-1883.
- [3]SANDER V, PHILIP D, IOANNIS G, et al. Hyperspectral remote sensing of fire: state-of-the-art and future perspectives[J]. Remote sensing of environment, 2018, 216: 105-121.
- [4]赵涛, 彭峰, 周发超, 等. 基于可控多样性生成对抗网络的水环境遥感影像场景分类方法[J]. 西北水电, 2023(4): 42-49.
- [5]秦望博, 葛斌. 基于多尺度特征融合的遥感影像场景分类方法[J]. 佳木斯大学学报(自然科学版),2024,42(1):6-9+20.
- [6]SZEGEDY C, LIU W, JIA Y, et al.Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE,2015:1-9.
- [7]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).Piscataway: IEEE, 2016: 770-778.
- [8]YU F, WANG D, SHELHAMER E, et al.Deep layer aggregation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition.Piscataway: IEEE, 2018: 2403-2412.
- [9]GAO S, CHENG M, ZHAO K, et al.Res2Net: a new multi-scale backbone architecture[J].IEEE transactions on pattern analysis and machine intelligence, 2019,43(2):652-662.
- [10]逯登科, 罗亦冰, 张紫怡, 等. 基于 ResNet50 与通道注意力的遥感图像场景分类[J]. 江西科学,2024,42(2):396-404.
- [11]朱杰凡, 张明虎, 丁超, 等. 基于 ResNet 的遥感图像场景识别及分类技术[J]. 计算机与数字工程,2023,51(2):479-483.
- [12]杨星, 宋玲玲, 王时绘. 基于改进的 ResNeXt 网络结构的遥感图像分类[J]. 计算机科学, 2023,50(S1):282-287.
- [13]吕欢欢, 彭国峰, 张辉. 深度可分离残差网络的高分遥感影像场景分类[J]. 测绘科学, 2023,48(4):129-139.
- [14]DING X, ZHANG X, HAN J, et al. Scaling up your kernels to 31×31 : Revisiting large kernel design in CNNs[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Piscataway:IEEE,2022:11963-11975.
- [15]邓广远, 王红成. 基于通道混洗和深度可分离卷积的混合型晶圆缺陷识别[J]. 东莞理工学院学报,2024,31(3):17-23.
- [16]TAN M, LE Q V.Efficientnetv2: smaller models and faster training[EB/OL].(2021-06-23)[2024-05-01].<https://arxiv.org/abs/2104.00298v2>.
- [17]孙俊, 贾忆琳, 吴兆祺, 等. 基于改进 YOLOv7 的棉田虫害检测[J]. 农业工程学报,2024,40(10):176-184.
- [18]韩康, 战洪飞, 余军合, 等. 基于空洞卷积和增强型多尺度特征自适应融合的滚动轴承故障诊断[J]. 浙江大学学报(工学版), 2024,58(6):1285-1295.
- [19]BHOJWANI H, BHAVSAR V, GAJJAR R, et al.Image resolution enhancement using convolutional autoencoders with skip connections[C]//International Conference on Range Technology (ICORT). Piscataway:IEEE,2021:1-5.
- [20]李子茂, 于舒, 郑禄, 等. 基于融合注意力机制的小样本遥感场景分类方法[J]. 国外电子测量技术,2023,42(7):59-67.
- [21]余甜微, 郑恩让, 沈钧戈, 等. 基于多级别跨层双线性融合的光学遥感图像场景分类[J]. 光子学报, 2022, 51(2): 260-273.
- [22]段烨, 陈国坤, 李佳田, 等. 一种多尺度特征关联网络的遥感影像场景分类方法[J]. 遥感信息,2023,38(5):157-164.

【作者简介】

张冬梅(1995—), 女, 山西晋城人, 硕士, 助教, 研究方向: 计算机视觉。

宋子涛(1994—), 男, 山西晋城人, 硕士, 助教, 研究方向: 机器学习。

(收稿日期: 2024-07-28)