

# 基于深度学习光谱特征提取的城市 遥感地物目标分割方法

徐颖慧, 刘锋华

(江西农业大学 南昌商学院, 江西 共青城 332020)

**摘要:** 城市遥感影像复杂背景多重语义, 通过简单的形态学运算难以获取细微信息, 只能获取地物目标表层特征, 目标分割的像素易错乱, 导致分割结果不理想; 为此, 提出基于深度学习光谱特征提取的城市遥感地物目标分割方法; 利用高通与低通滤波器对图像中每个像元的光谱向量进行一维小波分解, 并通过指数函数非线性增强, 凸显微小光谱特征; 基于堆栈自动编码器构建深度学习模型, 提取深层次光谱特征; 运用模糊 C 均值聚类算法, 根据特征像元相似度进行初步分割; 引入自适应区域生长算法, 以初步分割结果中的种子点出发, 进行二次精细分割, 得到修正后的准确分割结果; 实验结果表明: 面向简单背景的城市遥感图像, 该方法分割结果 MIoU 值保持在 0.55 以上, 而遇到复杂背景的遥感图像, 其分割结果 MIoU 值也超过了 0.5, 极大提升了遥感图像分割处理质量。

**关键词:** 深度学习; 堆栈自动编码器; 光谱特征; 遥感图像; 城市地物; 分割

## Segmentation Method for Urban Remote Sensing Land Objects Based on Deep Learning Spectral Feature Extraction

XU Yinghui, LIU Fenghua

(Nanchang Business College of JXAU, Gongqingchengshi 332020, China)

**Abstract:** Urban remote sensing images have complex backgrounds and multiple semantics, making it difficult to obtain subtle information through simple morphological operations, which can only obtain surface features of ground objects and easily confuse pixels in the target segmentation, resulting in unsatisfactory segmentation results. Therefore, a segmentation method for urban remote sensing land objects based on deep learning spectral feature extraction is proposed. Using high pass and low-pass filters to perform one-dimensional wavelet decomposition on the spectral vector of each pixel in the image, and nonlinearly enhance it through an exponential function to highlight subtle spectral features. Build a deep learning model based on a stack autoencoder mechanism to extract deep spectral features. Based on the similarity of feature pixels, using the fuzzy C-means clustering algorithm to perform the preliminary segmentation. Introducing an adaptive region growing algorithm to perform secondary fine segmentation based on seed points from preliminary segmentation results, thereby obtaining corrected and accurate segmentation results. Experimental results show that for urban remote sensing images with simple backgrounds, the segmentation MIoU value of this method remains above 0.55, while the MIoU value of the segmentation also exceeds 0.5 for remote sensing images with complex backgrounds, greatly improving the quality of remote sensing image segmentation processing.

**Keywords:** deep learning; stack autoencoder; spectral characteristics; remote sensing images; urban land objects; division

## 0 引言

现代遥感设备能够捕获到高空间分辨率、多光谱及

高光谱数据, 在城市规划、环境监测、交通管理等领域发挥巨大应用价值<sup>[1]</sup>。目标分割是遥感图像处理中的一个重要环节, 其目的是从图像中准确识别并分割出各种

收稿日期: 2025-01-07; 修回日期: 2025-02-25。

基金项目: 江西省教育厅科学技术研究项目(GJJ218201)。

作者简介: 徐颖慧(1981-), 男, 博士, 讲师。

引用格式: 徐颖慧, 刘锋华. 基于深度学习光谱特征提取的城市遥感地物目标分割方法[J]. 计算机测量与控制, 2026, 34(1): 125

- 133.

地物目标,如建筑物、道路、植被、水体等<sup>[2]</sup>,这些地物目标的精确识别有利于揭示城市的空间布局和交通网络、评估城市的生态环境质量,指导城市未来发展方向<sup>[3]</sup>。但由于城市遥感图像目标种类繁多、形态各异、背景复杂,地物目标分割工作面临严峻挑战。因此,各种融合智能算法的城市遥感地物目标分割方法涌现出来。

文献 [4] 提出基于改进模糊均值聚类算法的分割技术,以样本特征值平方差为指标,度量图像中不同特征之间的相似度。应用模糊均值聚类算法,在考虑空间分布特征的情况下,将相似度较高的特征划分为一类,实现对图像目标的分割。但在处理复杂背景或纹理丰富的遥感图像时,难以准确区分不同类别的像素,导致分割结果不准确。文献 [5] 提出基于双模态高效特征学习的分割方法,应用深度学习网络构建特征提取模型,获取遥感图像中包含的双模态特征。再引入一个编码器,实现双模态特征聚合和深层次特征提取,反映图像语义细节信息。面向所有图像特征进行分类处理,即可完成遥感图像目标分割。但其特征提取不够充分,导致最终分割结果不准确。文献 [6] 提出自适应形态学与多尺度结合的分割方法,依托于一般自适应邻域网络,构造面向遥感图像的形态学复合型滤波器,通过对图像展开膨胀运算和腐蚀运算,消除图像干扰噪声。再引入多尺度分割算法,对滤波后的图像进一步处理,即可实现遥感图像目标区域的多尺度分割。但无法确定合理的尺度参数,部分像素误分类,降低分割结果的准确性。文献 [7] 提出基于新型神经网络的分割方法,针对遥感图像进行变换,得到其对应的强度-色调-饱和度图像,再应用高阶统计算法增强图像光谱信息。以新型神经网络为核心建立特征提取模型,获取图像多尺度特征信息,结合边缘检测算法对特征信息进一步分析,即可输出遥感目标分割结果。但面临着训练数据不足或标注不准确的情况,导致算法仅能识别表层特征,在分割时不够准确。

为此,提出基于深度学习光谱特征提取的城市遥感地物目标分割方法。充分利用深度学习在深层特征提取方面的优势,通过构建深度神经网络模型来自动提取光谱特征,基于此实现对城市遥感地物目标的精确分割,为城市规划、环境监测、灾害预警等领域提供有力的技术支持。

## 1 城市遥感地物目标分割方法

为确保城市遥感地物目标分割的准确性和可靠性,本文结合光谱特征增强、深度学习特征提取、模糊聚类分割和自适应区域生长修正等技术,对城市遥感图像进行挖掘。首先,对采集的城市遥感图像进行光谱特征增

强。这一步通过一维小波分解方法对每个光谱向量进行分解,并对分解后的小波系数进行非线性增强,以凸显原始遥感图像中的光谱特征,提供更为清晰、特征明显的图像数据。接着,利用深度学习模型——堆栈自动编码器,对增强后的光谱特征进行提取。通过不断学习,该模型能够输出图像包含的深层次光谱特征。然后,采用模糊 C 均值聚类算法,根据特征像元的相似度,将相似度较高的像元划分为同一类,对提取出的深层次光谱特征进行聚类分割,从而实现遥感地物目标的初步分割。为了修正初步分割结果,引入自适应区域生长算法进行二次分割处理。这一步以初步分割后形成的地物目标为基础,设置最小外接矩形框作为初始种子点,根据像素灰度值差异进行区域生长。在生长过程中,添加自适应调节因子以增强算法的自适应性,以应对复杂背景下的不同类型遥感地物目标。最后,当生长区域扩大范围超过设定的生长空间时,停止二次分割,得到城市遥感地物目标的最终分割结果。这一结果经过初步聚类分割和自适应区域生长分割修正,能够更准确地反映遥感图像中的地物目标分布。具体实现流程如图 1 所示。

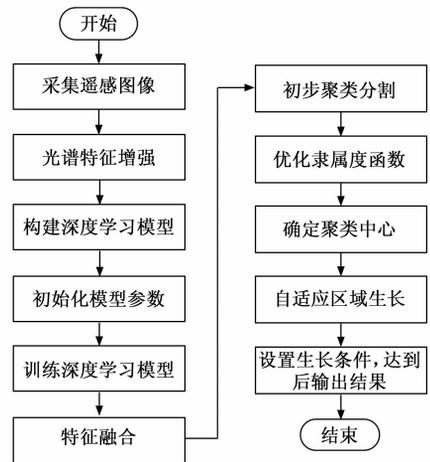


图 1 城市遥感地物目标分割流程示意图

### 1.1 城市遥感图像光谱特征增强

借助遥感技术采集的城市遥感图像中,每个像元都可以被视为一个包含光谱信息的一维向量。为了凸显图像内的特征信息,采用一维小波分解方法对每个光谱向量进行分解<sup>[8]</sup>,并对分解后的小波系数进行非线性增强,从而凸显原始遥感图像中的光谱特征<sup>[9]</sup>,为后续城市遥感地物目标分割提供依据。其中,一维小波分解需要在一个滤波器组的辅助下完成。将城市遥感影像中像素点对应的光谱向量看作输入变量,并赋予其一个小波系数,通过高通滤波器、低通滤波器分别对光谱向量进行分解<sup>[10]</sup>,最终输出两个小波系数向量,以此来描述遥感图像中光谱信号的细节特征。

面向一维小波分解后的光谱向量,应用指数函数对

其进行非线性变换, 即可得到:

$$A' = a_1(X \otimes a_2), a_2 \geq 1 \quad (1)$$

其中:

$$X = [x_1, x_2, \dots, x_m] \quad (2)$$

式中,  $A'$  表示非线性增强后形成的图像光谱向量,  $a_1$ 、 $a_2$  表示调节因子,  $X$  表示一维小波分解后遥感图像像素点对应的小波系数向量,  $x$  表示小波系数值,  $m$  表示图像波段数,  $\otimes$  表示指数函数运算符号<sup>[11]</sup>。

通过公式 (1) 展开非线性变换运算时, 指数函数的应用实现了对原始向量中每个分量的  $N$  次方运算, 如公式 (3) 所示:

$$X \otimes a_2 = [x_1^{a_2}, x_2^{a_2}, \dots, x_m^{a_2}] \quad (3)$$

针对一维小波分解后的小波系数向量进行非线性变换, 实现每个像元光谱向量中微小分量的增强, 使得不同波段光谱特征差异明显, 有利于揭示细微的光谱特征变化。

### 1.2 基于深度学习的光谱特征提取

以包含 4 层网络结构的堆栈自动编码器为核心, 构建基于深度学习的光谱特征提取模型, 如图 2 所示。将光谱特征增强后的城市遥感图像输入模型中, 通过不断学习可以输出图像包含的深层次光谱特征, 为遥感地物目标分割提供支撑。

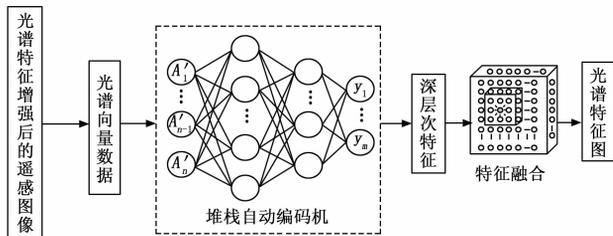


图 2 光谱特征提取模型

图 2 中,  $n$  表示城市遥感图像中像元数量, 即原始图像中光谱向量数目。

面向增强后的城市遥感图像, 获取每个像元对应的光谱向量数据, 将其输入堆栈自动编码器中进行学习, 即可输出深层次特征提取结果<sup>[12]</sup>。这一过程中, 深层次光谱特征的递归运算公式为:

$$\begin{cases} B' = S(w_1 \times A'_k + b_1) \\ B'' = S(w_2 \times B' + b_2) \\ y = S(w_3 \times B'' + b_3) \end{cases} \quad (4)$$

式中,  $B'$ 、 $B''$  通过两个隐含层学习得到的深层光谱特征,  $y$  表示整个堆栈自动编码器网络提取的深层次光谱特征,  $S$  表示激活函数 sigmoid,  $w_1$ 、 $w_2$ 、 $w_3$  表示连接权重,  $k$  表示光谱向量数据编号,  $b_1$ 、 $b_2$ 、 $b_3$  表示偏置值。其中, 连接权重决定神经元之间连接的强度, 用以控制信息的流动。偏置决定神经元自身的激活阈值, 用以控制神经元的激活。权重和偏置的使用让神经网络拥有强大

的表达能力和学习能力。权重调整应遵循梯度下降的方向, 同时考虑学习率的大小, 以避免过快的收敛或陷入局部最优解。同时限制偏置值的调整范围在激活函数的饱和区域内, 避免神经元过度激活或抑制。

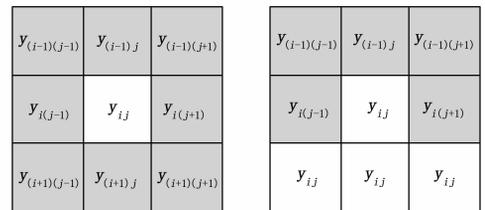
在堆栈自动编码器处理城市遥感图像的光谱特征提取任务中, 采用 Xavier 初始化方法进行权重初始化, 根据输入和输出神经元的数量自适应地调整权重的初始尺度。对于第一层隐含层, 其权重  $W_1$  可以从一个以 0 为均值, 方差为  $1/(\text{输入神经元数量})$  的正态分布中随机抽取。同样地, 第二层隐含层的权重  $W_2$  也遵循类似的初始化原则, 但其方差应调整为  $1/(\text{第一层隐含层神经元数量})$ 。在训练过程中, 通过反向传播算法根据损失函数对权重的梯度进行迭代更新。偏置值的设置相对简单, 初始化为 0。在训练开始时, 偏置值将随着反向传播算法的应用而逐渐调整, 以最小化损失函数。通过迭代地更新权重和偏置值, 堆栈自动编码器能够学习到从输入光谱向量到深层次光谱特征的复杂映射关系, 确保了模型能够从遥感图像中提取出有用的光谱特征。

根据堆栈自动编码器输出的深层次特征, 绘制出一个特征图, 从中确定任意一个特征像元, 以此为中心构造方形窗口<sup>[13]</sup>, 窗口覆盖区域就是特征像元的近邻空间:

$$\alpha(y_{ij}) = \left\{ y'_{uv} \mid u \in \left[ i - \left( \frac{c-1}{2} \right), i + \left( \frac{c-1}{2} \right) \right], v \in \left[ j - \left( \frac{c-1}{2} \right), j + \left( \frac{c-1}{2} \right) \right] \right\} \quad (5)$$

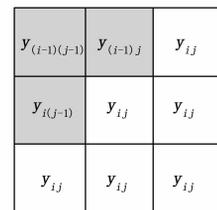
式中,  $i$ 、 $j$  分别表示特征像元的行编号和列编号,  $\alpha$  表示近邻空间,  $y'$  表示近邻像元,  $u$ 、 $v$  表示近邻像元的行编号和列编号,  $c$  表示窗口大小。

在构造特征像元近邻空间时, 需要考虑选中的特征像元所处位置, 采用不同方式填充窗口<sup>[14]</sup>, 如图 3 所示。



(a) 处于中心

(b) 处于边缘



(c) 处于角落

图 3 特征像元近邻空间

当特征像元处于图像中心区域, 其四周像元均需要

进行填充, 但当特征像元位于图像边缘和角落时, 则需要适当填充周围像元。

确定特征像元近邻空间后, 通过公式 (6) 计算出特征像元与近邻像元之间的相似度:

$$\chi_{uv} = \frac{y_{ij} \times y'_{uv}}{\|y_{ij}\| \times \|y'_{uv}\|} \quad (6)$$

式中,  $\chi$  表示相似度。

以相似度计算结果为依据, 对堆栈自动编码器给出的深层次特征进行融合<sup>[15]</sup>, 最终得到:

$$\hat{y}_{ij} = \frac{\sum_{y'_{uv} \in \alpha(y_{ij})} \chi_{uv} \times y'_{uv}}{\sum_{y'_{uv} \in \alpha(y_{ij})} \chi_{uv}} \quad (7)$$

式中,  $\hat{y}$  表示融合空间信息的特征矢量。

通过基于深度学习的特征提取、考虑空间信息的特征融合两个操作, 得到城市遥感图像深层次光谱特征, 有助于后续地物目标分割。

### 1.3 城市遥感地物目标聚类分割算法

获取遥感图像光谱特征后, 采用模糊 C 均值聚类算法<sup>[16]</sup>, 将相似度较高的特征像元划分为一类, 遍历所有特征就可以完成城市遥感地物目标初步分割<sup>[17]</sup>。遥感地物目标聚类分割过程中, 定义目标函数为:

$$\min J_r(\mathbf{U}, \mathbf{V}) = \sum_{p=1}^P \sum_{q=1}^Q (\eta_{pq})^r \gamma_{pq}^2 \quad (8)$$

其中:

$$\gamma_{pq}^2 = \|\hat{y}_q - \delta_p\|^2 \quad (9)$$

式中,  $\min$  表示最小值取值函数,  $J$  表示遥感地物目标聚类分割目标函数,  $r$  表示加权指数,  $\mathbf{U}$ 、 $\mathbf{V}$  分别表示隶属度矩阵和聚类中心矩阵,  $P$ 、 $p$  表示城市遥感地物目标数量和聚类中心编号,  $Q$ 、 $q$  表示遥感图像中特征像元数量和特征像元编号,  $\eta$  表示隶属度,  $\gamma$  表示聚类中心与特征像元之间的距离,  $\delta$  表示聚类中心。

考虑城市遥感地物目标聚类要求, 给定公式 (10) 所示的约束条件:

$$\begin{cases} \sum_{p=1}^P \eta_{pq} = 1, 1 \leq q \leq Q \\ \eta_{pq} \in [0, 1], 1 \leq p \leq P \end{cases} \quad (10)$$

遥感图像地物目标聚类分割过程中, 最优隶属度函数的确定需要借助于拉格朗日乘子, 如公式 (11) 所示:

$$\eta_{pq} = \frac{1}{\sum_{t=1}^P \left( \frac{\gamma_{pt}}{\gamma_{qt}} \right)^{2/(r-1)}} \quad (11)$$

式中,  $t$  表示另外一个随机选定的聚类中心。

引入特征相似度、空间分布特征两方面信息<sup>[18]</sup>, 对公式 (12) 给出的隶属度函数进行优化, 得到:

$$\eta'_{pq} = \eta_{pq} \times \bar{\tau}_q = \eta_{pq} \times \frac{1}{\lambda} \sum_{z=1}^{\lambda} \tau_{qz} \quad (12)$$

$$\eta''_{pq} = \frac{(\eta'_{pq})^{f_1} (\partial_{pq})^{f_2}}{\sum_{t=1}^P (\eta'_{pt})^{f_1} (\partial_{pt})^{f_2}} \quad (13)$$

式中,  $\eta'$  表示考虑特征相似度优化的最优隶属度函数,  $\eta''$  表示考虑特征相似度和空间分布特征的最优隶属度函数,  $\lambda$ 、 $z$  表示滑动窗口内特征像元数量和特征像元编号,  $\bar{\tau}$  表示平均相似度,  $f_1$ 、 $f_2$  表示控制两函数相对重要程度的参数,  $\partial$  表示空间邻域函数。

用公式 (13) 计算结果替换公式 (8) 中的原始隶属度函数, 以此来优化城市遥感地物目标聚类结果, 提升初步分割质量。同时, 基于优化后的隶属度函数, 可以推导出模糊聚类中心<sup>[19]</sup>:

$$v_p = \frac{\sum_{q=1}^Q (\eta''_{pq}) \hat{y}_q}{\sum_{q=1}^Q (\eta''_{pq})} \quad (14)$$

式中,  $v$  表示聚类中心。

明确隶属度函数和聚类中心后, 利用最大隶属度原则, 不断完成城市遥感图像特征像元的聚类, 直到相邻聚类中心之间的距离小于预先给定阈值<sup>[20]</sup>, 即可结束迭代运算, 生成遥感地物目标初步分割结果。

### 1.4 自适应区域生长分割修正

以城市遥感地物目标聚类分割结果为基础, 为了修正目标分割结果, 引入自适应区域生长算法<sup>[21]</sup>, 完成二次分割处理。针对初步分割后形成的地物目标, 设置一个最小外接矩形框, 并确定矩形框在遥感图像中的具体位置。将所取矩形框看作初始种子点<sup>[22]</sup>, 获取其周围邻域像素点的灰度值, 观察其与种子点灰度值之间的差异, 像素灰度值差小于判断阈值的邻域像素点看作生长区域<sup>[23]</sup>, 其与像素点暂时忽略, 再从新生长区域入手, 重新找寻邻域像素点, 以此实现区域不断生长, 如图 4 所示。

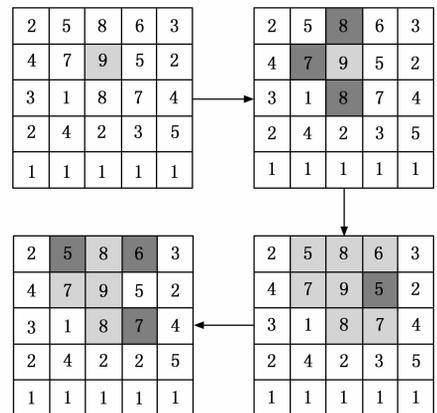


图 4 区域生长示意图

在区域生长过程中, 添加一个自适应调节因子<sup>[24]</sup>, 增强区域生长的自适应性, 以便应对复杂背景下不同类

型遥感地物目标的分割。自适应区域生长分割过程中, 将限制条件表示为公式 (15):

$$\psi_{\rho} = [\kappa_{\rho-1} - \theta F_{\rho-1}, \kappa_{\rho-1} + \theta F_{\rho-1}] \quad (15)$$

$$F_{\rho} =$$

$$\sqrt{(\bar{\omega}_{\rho} - \kappa_{\rho-1})^2 + \sqrt{(\bar{\omega}_{\rho-1} - \kappa_{\rho-2})^2 + \dots + \sqrt{(\bar{\omega}_1 - \kappa_0)^2}} \quad (16)$$

式中,  $\psi$  表示生长区间,  $\rho$  表示生长次数,  $\kappa$  表示生长区域的像素均值,  $\theta$  表示自适应调节因子,  $F$  表示生长区域的像素动态差,  $\bar{\omega}$  表示新加入像素灰度值,  $\kappa_0$  表示初始生长区域像素均值。

面向初步聚类分割后形成的遥感图像, 若生长区域扩大范围超过公式 (15) 给出的生长空间, 即可停止二次分割, 得到城市遥感地物目标分割修正结果<sup>[25]</sup>。

## 2 实验分析

以深度学习光谱特征提取为基础, 结合模糊 C 均值聚类、自适应区域生长算法, 研究出的城市遥感地物目标分割新方法, 主要是为了解决城市遥感图像中地物目标分割的复杂性和多样性问题。

在城市遥感图像中, 由于地物目标的多样性和复杂性, 传统的硬聚类方法往往难以得到理想的分割结果。模糊 C 均值聚类作为一种软聚类方法, 允许一个数据点同时属于多个类别, 并通过隶属度矩阵来描述这种关系。实验的其中一个目的, 是评估模糊 C 均值聚类算法在分割任务中的表现。

此外, 实验分析的核心目标是评估该方法在实际应用中的性能和效果, 判断应用堆栈自动编码器的提取遥感图像深层次光谱特征后, 能否基于此实现对城市遥感图像地物目标的准确识别, 为城市遥感图像处理和地物目标识别提供新的思路和方法。

### 2.1 数据集和评价指标

在实验验证基于深度学习光谱特征提取的城市遥感地物目标分割方法时, 构建一个高质量且富有代表性的数据集是至关重要的。ISPRS Vaihingen 数据集和 Potsdam 数据集是遥感图像处理领域的两个常用数据集, 其因为高精度、丰富的细节和多样化的地物目标而闻名, 遥感图像内建筑物、道路等各类地物均被赋予了鲜明的颜色, 有利于不同类型地物目标的准确区分。以这两个数据集为背景, 从中选择多幅城市遥感图像, 为实验提供了坚实的数据基础。

考虑到原始数据集中的图像尺寸较大, 直接上传到 GPU 进行训练不仅效率低下, 还可能因为内存限制而无法进行。为了解决这一问题, 在实验开始之前先对遥感图像进行了预处理, 将其切割成不重叠的小块图片, 最终产生了 1 300 幅城市遥感图像, 这些图像的尺寸均为  $256 \times 256$ 。这一步骤不仅降低了图像的尺寸, 还使

得数据集更加灵活, 便于后续模型训练和测试。为了提升深度学习光谱特征提取模型的泛化能力, 针对切割后的遥感图像进行翻转、转换、缩放等增强操作, 实现数据集的扩充, 如图 5 所示。数据集的扩充, 不仅能够增加数据集的多样性, 还能够模拟真实场景中的图像变化, 从而提高模型对复杂场景的适应能力。

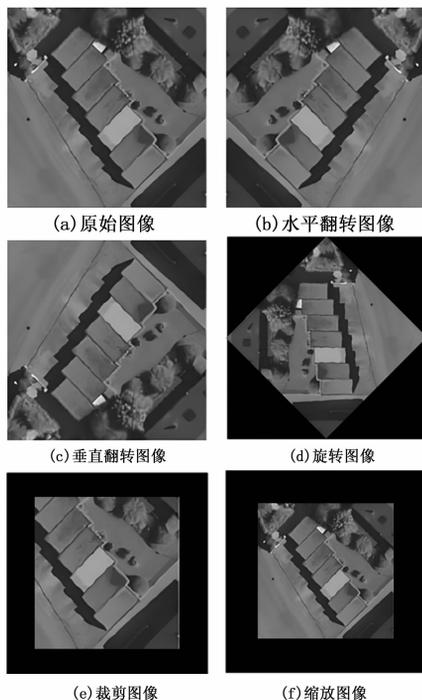


图 5 数据集扩充示例

按照图 5 所示的操作, 对数据集中所有遥感图像进行处理, 再经过筛选最终保留 7 000 张图像, 组成实验数据集。其中, 4 000 张是简单背景的遥感图像, 另外 3 000 张则是复杂背景的遥感图像。针对简单背景和复杂背景的遥感图像进一步划分, 形成包含 3 500 张、2 600 张图像的训练集, 以及包含 500 张、400 张图像的测试集, 应用到后续实验过程中。

表 1 实验数据集

| 背景特点 | 数据集类型 | 数据量/张 |
|------|-------|-------|
| 简单背景 | 训练集   | 3 500 |
|      | 测试集   | 500   |
| 复杂背景 | 训练集   | 2 600 |
|      | 测试集   | 400   |

其中, 简单背景和复杂背景的遥感图像部分样本如图 6 所示。

面向上述实验数据, 运用本文设计的基于深度学习光谱特征提取的方法、文献 [4] 的基于改进模糊均值聚类算法的分割技术、文献 [5] 的基于双模态高效特征学习的分割方法, 分别完成城市遥感地物目标分割实

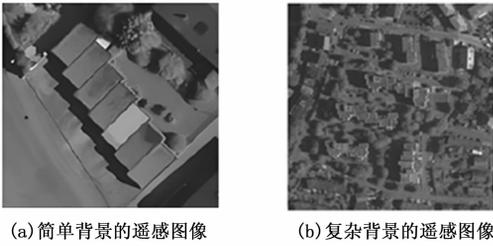


图 6 简单背景和复杂背景的遥感图像部分样本

验。其中，基于改进模糊均值聚类算法的分割技术的关键参数聚类数目 5，加权指数 2，迭代停止阈值  $1e-5$ 。基于双模态高效特征学习的分割方法的关键参数网络层数 3，神经元数量 128，学习率 0.01，批量大小 32，迭代次数 2 000。

为了通过对比体现新设计方法的优越性，采用均交并比作为评估指标，度量各方法分割结果的准确程度。均交并比计算公式为：

$$v = \frac{1}{N+1} \sum_{o=0}^N \frac{s_{o\alpha}}{\sum_{l=0}^N s_{o\alpha} + \sum_{l=0}^N s_{lo} - s_{o\alpha}} \quad (17)$$

式中， $v$  表示均交并比 (MIoU)， $N$  表示城市遥感地物目标分割数量， $o, l$  表示城市地物目标编号， $s$  表示像素数量和， $s_{o\alpha}$  表示本属于  $o$  却被划分到  $l$  的像素数量， $s_{lo}$  表示本属于  $l$  却被划分到  $o$  的像素数量， $s_{oo}$  表示属于  $o$  又正确划分为  $o$  的像素数量。

### 2.2 深度学习参数设置

堆栈自动编码器，是深度学习光谱特征提取模型的核心，也是遥感目标分割方法实施的基础。因此，在实验开始之前，先对堆栈自动编码器的基础参数进行设置，如表 2 所示。

表 2 堆栈自动编码器参数

| 参数名称      | 取值             |
|-----------|----------------|
| 堆栈自动编码器层数 | 4 层            |
| 各层节点数     | 103,150,100,50 |
| 批量大小      | 64             |
| 迭代次数      | 1 000          |
| 正则化系数     | 0.000 1        |
| 稀疏性参数     | 0.1            |
| 稀疏性惩罚项    | 3              |
| 激活函数      | ReLU           |
| 优化算法      | Adam           |

考虑到学习率、窗口大小两项参数，对深度学习光谱特征提取模型的应用性能有直接影响。应用实验数据训练集，对不同参数设置条件下的模型进行训练，观察模型表现，从而确定最优参数值。

将学习率设置为 0.000 1、0.000 3、0.000 5、0.000 7、0.001、0.003、0.005，其余参数保持固定不

变，观察不同学习率下深度学习模型特征提取结果 ACC 值变化，以及模型运算过程中产生的损失值变化，绘制出图 7 所示的变化曲线。

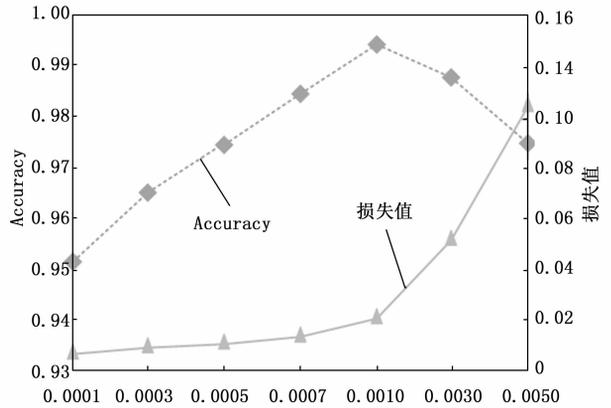


图 7 不同学习率下模型训练 ACC 值和损失值变化

从图 7 可以看出，在随着学习率不断增大，模型训练损失值逐渐上升，而特征提取结果 ACC 值则是呈现出先上升后下降的变化趋势。综合这两项指标可以看出，当学习率设置为 0.001 时，深度学习特征提取模型的损失值小于 0.02、ACC 值超过了 0.99，此时模型性能处于最优状态。

将学习率参数调整到最优后，设置方形窗口的大小从 1 变化为 19，并分析模型训练结果 ACC 值变化，得到图 8 所示的统计结果。

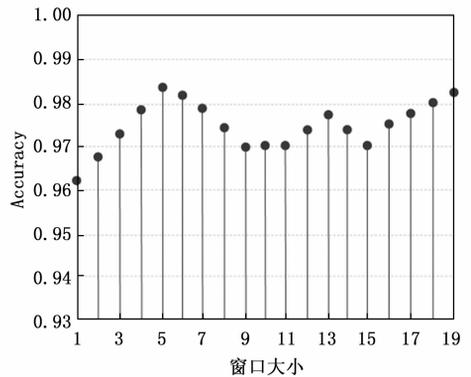


图 8 不同窗口大小下特征提取结果 ACC 值

从图 8 可以看出，当窗口大小为 5 时，深度学习光谱特征提取模型训练结果的 ACC 值最大。因此，为了保证模型的特征提取质量，在参数设置阶段将窗口大小取值结果固定为 5。

### 2.3 光谱特征增强结果

以测试集中的任意一幅城市遥感图像为例，应用新方法对其进行地物目标分割时，需要先完成原始图像光谱特征增强处理，以达到凸显细节特征、抑制干扰噪声的目的，最终呈现出的光谱特征增强实验结果如图 9

所示。

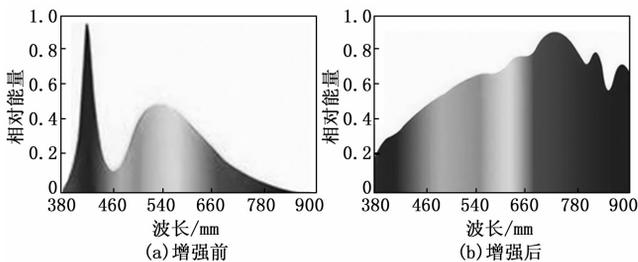


图 9 图像光谱特征增强效果

从图 9 (a) 可以看出, 原始遥感图像中目标点与背景点区分不明显, 这会对后续特征提取和目标分割产生极大影响。而从图 9 (b) 来看, 增强处理后目标点的光谱特征得到明显增强。

### 2.4 遥感地物目标分割结果

应用参数调整后的深度学习模型, 提取增强后遥感图像中包含的光谱特征, 将其代入到模糊 C 均值聚类过程中, 即可得到图 10 所示的初步聚类分割结果。



图 10 遥感图像地物目标聚类分割结果

如图 10 所示, 通过模糊 C 均值聚类分割, 原始遥感图像中不同地物目标所在区域得到了初步分割。但是, 初步分割结果中边界部分存在混淆问题, 无法清晰表示地物目标边界。

再引入自适应区域生长算法, 对初步聚类分割结果进一步修正, 即可得到城市遥感地物目标分割最终分割结果, 如图 11 和图 12 所示。

图 11 和图 12 分别给出的是简单背景、复杂背景下的城市遥感地物目标分割结果, 从这两个结果来看, 基于深度学习光谱特征的方法, 可以在不同场景中完成不同地物目标的准确分割, 边界平滑且划分明显, 最终分割结果与原图标签基本一致, 这表明了该分割方法的应用效果满足预期要求。

### 2.5 方法性能分析

应用不同方法对测试集中的城市遥感图像依次完成分割, 统计遥感地物目标分割结果, 并借助公式

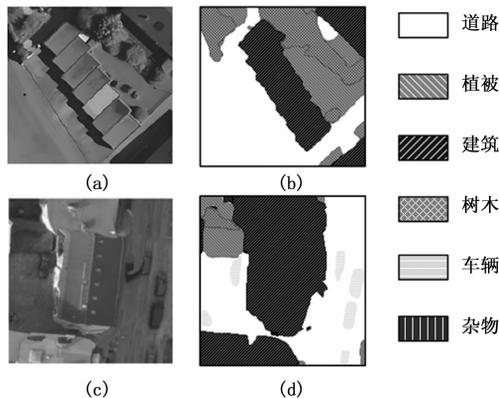


图 11 简单背景下地物目标分割结果

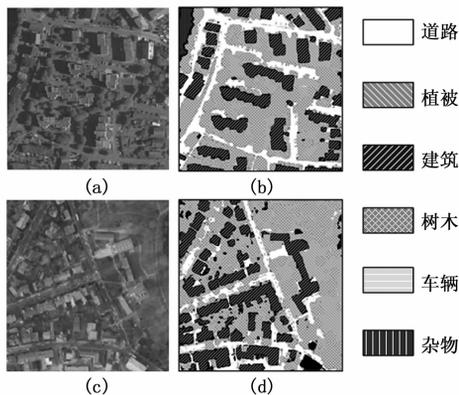


图 12 复杂背景下地物目标分割结果

(17) 完成 MIoU 值计算, 通过 MIoU 值对比体现各方法应用性能。以 30 张简单背景遥感图像和 30 张复杂背景遥感图像为例, 其表现出的 MIoU 值对比结果如图 13 所示。

从图 13 给出的对比结果可以看出, 以深度学习光谱特征提取为基础的新型分割方法, 可以生成更加准确的地物目标分割结果。面向简单背景的城市遥感图像, 其 MIoU 值保持在 0.55 以上, 而其余两种方法的 MIoU 值未超过 0.5。而在处理复杂背景的遥感图像时, 新方法表现出的 MIoU 值也在 0.5 以上, 此时另外两种方法分割结果 MIoU 值下降到 0.4 以下。综合来看, 深度学习光谱特征提取模型的应用, 实现了对遥感图像深层次特征的有效提取, 而模糊 C 均值算法和自适应区域生长算法的配合, 也推动了遥感图像分割质量的提升。

## 3 实验结果与分析

基于上述实验结果, 在面向简单背景的城市遥感图像中, 该方法分割结果的 MIoU 值保持在 0.55 以上。这是因为该方法通过高通和低通滤波器进行一维小波分解, 结合指数函数的非线性增强, 有效凸显了遥感图像中的微小光谱特征, 为后续处理奠定了坚实基础。其

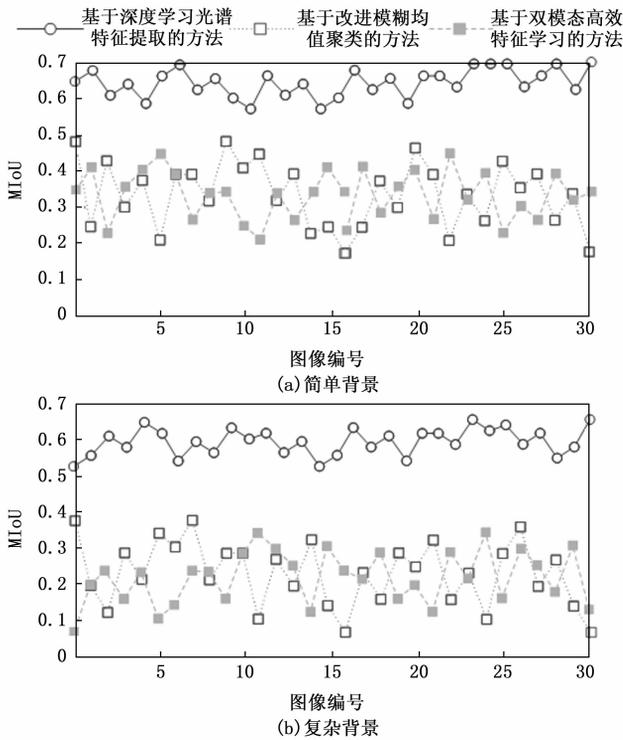


图 13 不同方法分割结果 MIoU 对比

次, 利用堆栈自动编机构建的深度学习模型, 自动学习并提取出遥感图像的深层次光谱特征, 这些特征更具代表性和区分度, 显著提升了特征提取的准确性和效率。最后, 采用模糊 C 均值聚类算法进行初步分割, 并引入自适应区域生长算法对边界进行精细修正, 有效解决了初步分割结果中的边界混淆问题, 进一步提高了分割结果的准确性和精细度。综合应用以上技术, 使得该方法在城市遥感地物目标分割中表现出色。

在面对复杂背景的遥感图像时, 该方法同样表现出优越的分割性能, 其分割结果的 MIoU 值超过了 0.5。这是因为该方法在复杂背景条件下, 通过结合一维小波分解与非线性增强的光谱特征增强技术, 以及基于堆栈自动编机构的深度学习特征提取模型, 该方法能精准捕捉图像中的深层次光谱特征, 为后续分割提供坚实的信息支撑。同时, 自适应区域生长算法根据复杂背景信息自动调整策略, 精细修正初步分割结果中的边界, 有效解决了边界混淆问题。此外, 整个分割流程各环节紧密协同、优化配合, 确保该方法在复杂背景下仍能保持高分割性能和稳定性, 展现出显著的优势。

综上所述, 基于深度学习光谱特征提取的城市遥感地物目标分割方法, 通过深度神经网络的应用和模糊 C 均值聚类的协同优化, 实现了对遥感图像中地物目标的精确分割。无论是面对简单背景还是复杂背景的遥感图像, 该方法都能够取得较好的分割效果, 为城市遥感图像的解译和应用提供了有力支持。

## 4 结束语

面向城市遥感地物目标分割问题, 提出基于深度学习光谱特征提取的新方法, 通过深度神经网络的高效特征提取能力, 成功从城市遥感图像中捕获了丰富的光谱特征信息。这些特征不仅涵盖了地物目标的内在属性, 还反映了其与环境间的复杂关系, 为后续分割任务奠定了坚实基础。在此基础上, 引入了模糊 C 均值聚类算法, 利用该算法对特征空间进行高效划分, 实现了对不同地物目标的初步分割。通过结合自适应区域生长算法, 进一步细化了分割结果, 有效解决了传统聚类方法在边界处理上的不足。实验结果表明, 该方法能够准确分割出城市遥感图像中的多种地物目标, 如建筑物、道路、植被等, 且分割边界清晰、连续, 为推动城市遥感技术的智能化发展做出了积极贡献。

### 参考文献:

- [1] 张银胜, 单梦姣, 陈昕, 等. 基于多模态特征提取与层级感知的遥感图像分割 [J]. 地球信息科学学报, 2024, 26 (12): 2741-2758.
- [2] 廖晓芳, 胡新乾. 基于改进 TSO 优化图像熵的图像识别与分割 [J]. 计算机工程与设计, 2024, 45 (11): 3471-3478.
- [3] 贾克斌, 何岩, 魏之皓. 融合多尺度特征的高分辨率森林遥感图像分割 [J]. 北京工业大学学报, 2024, 50 (9): 1089-1099.
- [4] 陈幸, 陈盛华, 陈国华, 等. 基于改进模糊均值聚类算法的遥感图像分割技术 [J]. 沈阳工业大学学报, 2023, 45 (6): 716-720.
- [5] 张银胜, 吉茹, 童俊毅, 等. 基于双模态高效特征学习的高分辨率遥感图像分割 [J]. 遥感学报, 2024, 28 (2): 481-493.
- [6] 李新娜, 王小鹏, 魏统艺. 自适应形态学与多尺度结合的植被区域遥感图像分割方法 [J]. 激光与光电子学进展, 2022, 59 (24): 240-246.
- [7] SONAVALA A, CHAKKARAVARTHY M, SRINIVASA RAO S, et al. Automatic semantic segmentation and classification of remote sensing image data for flood detection using novel LSTM neural network [J]. SN Computer Science, 2024, 5 (8): 1-10.
- [8] 金维, 李佳田, 段焯. SAA-UNet: 特征信息融合网络的遥感图像分割 [J]. 遥感信息, 2024, 39 (2): 156-163.
- [9] 马翔悦, 徐金东, 倪梦莹. 基于多尺度特征模糊卷积神经网络的遥感图像分割 [J]. 山东大学学报 (工学版), 2024, 54 (3): 44-54.
- [10] 吴嘉昕, 王小鹏, 刘扬洋. 子空间与 KL 信息结合的 FCM 多光谱遥感图像分割 [J]. 湖南大学学报 (自然科学版), 2024, 51 (8): 23-33.

- [11] 胡宇翔, 余长宏, 高明. 多模态融合的遥感图像语义分割网络 [J]. 计算机工程与应用, 2024, 60 (15): 234 - 242.
- [12] 苏 赋, 李 沁, 马 傲. 基于双路径编码的遥感建筑物图像分割方法 [J]. 计算机科学与探索, 2024, 18 (10): 2704 - 2711.
- [13] 席裕斌, 赵良军, 宁 峰, 等. 基于改进 DeepLabV3+ 的遥感图像分割方法 [J]. 现代电子技术, 2024, 47 (11): 51 - 58.
- [14] 李子怡, 曲婷婷, 崇乾鹏, 等. 基于模糊多尺度特征的遥感图像分割网络 [J]. 计算机应用, 2024, 44 (11): 3581 - 3586.
- [15] 李继文, 徐杰杰, 刘光灿. 特征融合注意力的遥感图像目标分割 [J]. 计算机工程与设计, 2023, 44 (11): 3402 - 3410.
- [16] 李政威, 汪西莉, 艾 美. 结合原型的两阶段遥感图像无监督域适应分割模型 [J]. 计算机科学与探索, 2024, 18 (8): 2091 - 2108.
- [17] 郭丹青, 符 颖, 朱 烨, 等. 自注意力多尺度特征融合的遥感图像语义分割算法 [J]. 计算机辅助设计与图形学学报, 2023, 35 (8): 1259 - 1268.
- [18] 吴 宁, 罗杨洋, 许华杰. 基于多尺度特征融合的遥感图像语义分割方法 [J]. 计算机应用, 2024, 44 (3): 737 - 744.
- [19] 胡涛涛, 李屹旭, 张 俊. 基于注意力机制改进的 Segformer 遥感图像语义分割方法 [J]. 激光杂志, 2024, 45 (7): 130 - 136.
- [20] 周 羿, 刘德儿. 融合注意力机制及 DenseASPP 改进的 DeeplabV3+ 遥感图像分割方法 [J]. 遥感信息, 2023, 38 (3): 85 - 92.
- [21] 刘春娟, 乔 泽, 闫浩文, 等. 基于多尺度互注意力的遥感图像语义分割网络 [J]. 浙江大学学报 (工学版), 2023, 57 (7): 1335 - 1344.
- [22] 李 玉, 崔书琳, 赵泉华. 基于优化 RDD 分区的 Spark 并行 K-means 大尺度遥感图像分割 [J]. 控制与决策, 2024, 39 (5): 1612 - 1619.
- [23] 李林娟, 贺 赟, 谢 刚, 等. 跨层细节感知和分组注意力引导的遥感图像语义分割 [J]. 中国图象图形学报, 2024, 29 (5): 1277 - 1290.
- [24] 梁 敏, 汪西莉. 结合超分辨率和域适应的遥感图像语义分割方法 [J]. 计算机学报, 2022, 45 (12): 2619 - 2636.
- [25] 王春艳, 金 鹏, 桂琪皓. 区间二型模糊神经网络遥感图像分割方法 [J]. 测绘科学, 2024, 49 (5): 84 - 98.
- (上接第 124 页)
- [10] 薛正燕. 卫星光通信捕获跟踪技术研究 [D]. 成都: 中国科学院研究生院 (光电技术研究所), 2015.
- [11] 钟 港. 大气光通信无信标捕获跟踪技术研究 [D]. 成都: 电子科技大学, 2022.
- [12] 滕云杰. 空间激光通信系统无信标捕获与跟踪技术 [D]. 长春: 长春理工大学, 2020.
- [13] LOPEZ J M, YONG K. Acquisition, tracking, and fine pointing control of space-based laser communication systems [C] // Control and Communication Technology in Laser Systems, SPIE, 1981, 295: 100 - 114.
- [14] LEI Y, LI X, ZHANG L. Experimental study on PAT system for Long-Distance laser communications between Fixed-Wing aircrafts [J]. Photonic Sensors, 2019, 9 (2): 70 - 178.
- [15] ZHAO Z F, ZHANG C Y, WANG X Y, et al. Research and Implementation on Sea-Based wireless laser communication PAT system [C] // 2024 8th International Conference on Imaging, Signal Processing and Communications (ICISPC), IEEE, 2024: 165 - 172.
- [16] 梅 博, 杨中华, 李梦男. 无信标星间激光通信系统粗精复合扫描方法 [J]. 红外与激光工程, 2022, 51 (6): 428 - 437.
- [17] LI Q, LIU L, MA X, et al. Development of multitarget acquisition, pointing, and tracking system for airborne laser communication [J]. IEEE Transactions on Industrial Informatics, 2018, 15 (3): 1720 - 1729.
- [18] ZHANG M, TONG S, SONG Y, et al. Modeling and reality analysis of beaconless spatial acquisition for intersatellite laser communication system [J]. Optical Engineering, 2017, 56 (10): 106108 - 106108.
- [19] WILLIAMS A J, LAYCOCK L L, GRIFFITH M S, et al. Acquisition and tracking for underwater optical communications [C] // Advanced Free-Space Optical Communication Techniques and Applications III, SPIE, 2017, 10437: 44 - 54.
- [20] 刘家燕, 程志峰, 王 平. 机载光电吊舱橡胶减振器的设计与应用 [J]. 中国机械工程, 2014, 25 (10): 1308 - 1312.
- [21] MAYNARD J A, BEGLEY D. Airborne laser communications: past, present, and future [C] // Free-Space Laser Communications V, SPIE, 2005, 5892: 82 - 94.
- [22] MOLL F, MITZKUS W, HORWATH J, et al. Demonstration of high-rate laser communications from fast airborne platform: flight campaign and results [C] // Unmanned/Unattended Sensors and Sensor Networks X, SPIE, 2014, 9248: 181 - 186.
- [23] 张 敏, 佟首峰, 滕云杰. 激光通信系统中的捕获技术及扫描策略研究 [J]. 激光杂志, 2019, 40 (10): 139 - 142.
- [24] 孟立新. 机载激光通信中捕获与跟踪技术研究 [D]. 长春: 吉林大学, 2014.