

MST-ViT：基于移位不变位置嵌入与残差池化的遥感图像分割模型

刘明阳¹ 陈美琳¹ 巩荣芬^{1*}

LIU Mingyang CHEN Meilin GONG Rongfen

摘要

近年来,视觉 Transformer (ViT) 在图像分类任务上取得了显著突破,但在处理高分辨率遥感图像分割以及时空视频理解任务时,仍面临计算复杂度和内存占用的双重挑战。针对一系列问题,文章对多尺度视觉 Transformer (multiscale vision transformers, MViT) 架构进行了创新性的优化。通过引入一种移位不变的位置嵌入策略,克服绝对位置嵌入的局限性,通过分解位置距离,使模型能更精准地捕捉位置信息;同时,针对传统池化操作可能引发的细节信息丢失问题,文章提出了残差池化连接方法,该方法通过融合池化前后的特征信息,有效提升了模型在遥感图像分割任务中的性能。最后,将优化后的 MViT 架构与标准的密集预测框架 SegFormer 相结合,进一步增强了模型在复杂遥感图像分割中的表现。实验结果显示 MST-ViT 模型在处理多尺度和复杂特征时展现出显著优势,同时在计算效率和性能之间实现了良好平衡,为 Transformer 模型在遥感图像分割领域的应用开辟了新的道路。

关键词

遥感图像分割; 残差池化连接; 多尺度; 自注意力机制; Transformer 模型优化; 密集预测框架

doi: 10.3969/j.issn.1672-9528.2025.07.030

0 引言

近年来,在设计用于遥感图像分割任务的架构方面,一直存在诸多挑战。传统 CNN 模型(如 VGGNet、ResNet)与新兴视觉 Transformer (ViT) 模型各有优劣,ViT 虽在分类任务表现优异,但在处理高分辨率遥感图像时,其全局自注意力的二次方计算复杂度会引发巨大计算负担^[1-2]。

如今,为解决这类问题,主要采用两种方法。其一是采用窗口化的注意力机制,例如 Swin Transformer,即通过分层次的方式,在图像的不同尺度上应用自注意力机制。首先在局部窗口内计算自注意力,然后再逐步扩大感受野。Swin Transformer 通过以上方法有效地减少了计算量,同时在保持局部细节的同时,能够捕捉到全局信息。作为特征提取骨干网络,Transformer 可以灵活地应用于各种视觉场景,包括遥感图像分类、目标检测和语义分割等。尽管 Swin Transformer 通过引入分层结构来扩大感受野,但局部窗口设计在捕捉全局信息时,仍不如全局自注意力机制那样精细。

另一种方法是采用池化注意力机制,例如多尺度视觉 Transformer (multiscale vision transformer, MViT) 模型。MViT

模型通过多尺度的方式,捕捉不同层次的特征,使其在处理具有复杂结构的遥感图像时表现出色。MViT 能够有效地整合不同尺度的信息,从而提升模型的性能,特别是在处理高分辨率遥感图像中的细节分割和目标检测任务时,具有明显优势。

1 工作介绍

为进一步提升 MViT 模型在遥感图像分割任务中的性能。首先,使用移位不变的位置嵌入克服绝对位置嵌入的局限性。该方法通过位置距离的分解形式,将位置信息更好地引入 Transformer 块,以增强模型对空间位置信息的感知能力,同时,在池化操作中,通常会通过下采样来减少计算量。然而,这种下采样操作可能导致部分细节信息的丢失,从而影响模型性能。为了解决这一问题,文章提出了 MST Block 模块,即在模块中使用了残差池化连接,通过在池化操作后添加残差连接,将原始输入特征与池化后的特征结合^[3],从而补偿注意力计算中由于池化步长带来的细节损失。最后,将优化后的 MViT 与类似于 SegFormer 模块堆叠方式结合,进一步提升了在复杂遥感图像分割任务中的表现。

经测试实验证实,此种对池化注意力机制的优化和 MViT 架构的改进,提升模型在处理多尺度和复杂特征时的能力的同时,还通过与标准密集预测框架的结合,显著增强

1. 辽宁科技大学电子与信息工程学院 辽宁鞍山 114051

[基金项目] 辽宁省大学生创新创业项目基金项目资助

了模型在遥感图像分割任务中的表现。这些改进为遥感图像分割中的 Transformer 模型提供了更强大的工具^[4], 平衡了计算效率与模型性能。

2 相关工作

2.1 视觉 Transformer (ViT)^[5]

Transformer 架构通过将图像分割为固定尺寸的图像块 (patches) 来应用于视觉任务, 这一创新在 ViT 模型中展现出了优异的图像分类性能。该方法的本质是将二维图像重构为块序列, 借助 Transformer 的全局关联建模能力来处理视觉信息。虽然该架构在基础分类任务中表现卓越, 但是在应对高分辨率图像处理及视频时空关系理解时仍存在局限性。核心制约因素在于自注意力机制的计算复杂度——当处理更高像素密度的视觉输入时, 其计算量会以输入尺寸平方级的速率增长, 这成为实际应用中的主要瓶颈。

2.2 多尺度视觉 Transformer (MViT)

针对 ViT 在多尺度特征提取上的不足, 研究者提出了多尺度视觉 Transformer (MViT) 架构^[6]。该模型通过层级式特征聚合机制, 实现了跨尺度视觉特征的动态建模, 显著提升了复杂视觉场景的解析能力。相较于传统 ViT 的扁平化处理方式, MViT 采用渐进式特征融合策略, 通过动态调整感受野范围, 在降低运算负荷的同时增强模型的多尺度适应性。值得注意的是, 虽然 MViT 在常规视觉基准测试中展现出很大的优势, 但在处理超高分辨率图像中的精细结构时, 模型仍存在特征分辨率下降的现象, 这驱动着网络架构设计与计算效率优化方面的持续探索。

2.3 SegFormer

SegFormer 是曹冠华等人^[7]提出的一种专为图像分割任务设计的 Transformer 架构。结合了 PVT 的多尺度特征提取能力和 Transformer 的全局建模能力。采用一种高效的自注意力机制, 同时结合了简单的解码器设计, 以实现高效且准确的分割性能。SegFormer 在多个语义分割任务中取得了优异的表现, 并展现了在复杂场景下的强大适应能力, 使其成为遥感图像分割任务的一个有力工具。

3 MST-ViT 模型

3.1 MST-ViT 模型介绍

MViT 凭借在多尺度特征提取方面的能力在计算机视觉任务中表现出色。在遥感图像分割任务中, MST-ViT 进一步优化 MViT 结构, 并与标准的密集预测框架——SegFormer 结合, 具体来说, 在标准的多头自注意力机制中, 模型通常需要从全局考虑每个元素与其他所有元素之间的相互作用。虽然这种全局依赖建模能力在解析复杂特征关联时具有明显

的优势, 但在处理大规模高分辨率的遥感图像时, 常常会导致计算成本上升。基于此问题, 空间压缩策略——池化注意力机制被引入, 通过建立关键区域的特征表征, 在减少计算复杂度的同时, 维持模型性能的优异表现^[8]。如图 1 所示, 这种结合利用多尺度特征的表达能力, 增强了模型在处理复杂地物分割任务时的表现, 尤其是在高分辨率遥感影像中。通过整合多尺度特征和密集预测, MST-ViT 在细粒度地物分割、目标检测和实例分割任务中均展现出了卓越的性能。




图 1 MST-ViT 模型结构

3.2 移位不变的位置嵌入

在标准的自注意力机制中, 位置嵌入是不可缺少的部分, 因为 Transformer 架构本身并不具备捕捉位置信息的能力。所以为明确每个元素的位置, 通常使用绝对位置编码。但在遥感图像分割任务中, 遥感影像的空间变换 (如平移、旋转等) 使得绝对位置编码不总是理想的。为了克服绝对位置嵌入的局限性, MST-ViT 提出了移位不变的位置嵌入策略。该方法通过位置距离的分解形式, 将位置信息引入 Transformer 块。具体来说, 模型计算相对位置距离, 而不是绝对位置, 从而在注意力计算中融入这些信息。这使得模型对输入图像的位置变化更具鲁棒性, 增强了对不同地物位置的平移不变性。此外, 这种相对位置编码减少了模型对精确位置的依赖, 使其更关注地物之间的相对空间关系, 从而提升了分割效果。

3.3 MST Block

在遥感图像分割任务中, 高分辨率影像中的细节信息至关重要。如图 2 所示, 标准的池化操作通过下采样来减少计算量, 但这往往会导致细节信息的丢失, 从而影响分割精度。为解决这一问题, MST-ViT 提出了 MST Block。具体来说, 通过在池化操作后添加残差连接, 模型将原始输入特征与池化后的特征结合^[9], 从而补偿注意力计算中由于池化步长带来的细节损失。使用这种差池化连接不仅保留了原始输入中的细节信息, 同时通过池化层有效降低了计算复杂度。这种设计确保了模型在保持高效计算的同时, 不会牺牲对遥感图像中细微地物特征的捕捉能力, 从而提升了遥感图像分割任

务中的整体性能。




图 2 MST Block

在该模型中，输入经过归一化、线性变换、池化，以及位置嵌入后，参与自注意力的计算，用公式表示为：

(1) 输入归一化：

$$\hat{X} = \text{Norm}(X) \quad (1)$$

式中： X 是输入特征； $\hat{X}$ 是经过归一化处理后的特征。

(2) 线性变换：对归一化后的特征进行线性变换，生成查询 (Q)、键 (K) 和值 (V) 向量：

$$Q = W_Q \hat{X}, \quad K = W_K \hat{X}, \quad V = W_V \hat{X} \quad (2)$$

式中： W_Q 、 W_K 、 W_V 分别是查询、键和值的线性变换矩阵。

(3) 池化操作^[10]：对查询、键和值进行池化，以减少计算复杂度：

$$Q_{\text{pool}} = \text{Pool}(Q), \quad K_{\text{pool}} = \text{Pool}(K), \quad V_{\text{pool}} = \text{Pool}(V) \quad (3)$$

(4) 相对位置嵌入：计算相对位置嵌入并加入注意力得分中：

$$A_{ij} = \frac{Q_{\text{pool},i} K_{\text{pool},j}^T}{\sqrt{d}} + E(i,j) + F(i,j) \quad (4)$$

式中： $E(i,j)$ 和 $F(i,j)$ 分别是计算的相对位置嵌入。

(5) 注意力得分计算：使用 Softmax 函数计算注意力权重为：

$$\alpha_{ij} = \text{Softmax}(A_{ij}) \quad (5)$$

(6) 注意力加权求和：根据注意力权重对值向量进行加权求和，得到自注意力输出为：

$$Z = \sum_j \alpha_{ij} V_{\text{pool},j} \quad (6)$$

(7) 残差连接^[11]：将池化前的输入特征与池化后的自注意力输出结合，形成残差连接为：

$$Z_{\text{res}} = Z + X \quad (7)$$

(8) 线性变换与输出：对残差连接后的输出再进行线性变换，得到最终的输出：

$$\text{Output} = W_O Z_{\text{res}} \quad (8)$$

式中： W_O 是输出的线性变换矩阵。

这一过程将标准的自注意力机制与池化操作、残差连接和相对位置嵌入结合，从而在降低计算复杂度的同时，增强了模型的位置信息感知能力，并保留了细节信息。

4 实验部分

4.1 数据集

实验采用武汉大学东亚卫星建筑数据集，该数据集专为深度学习模型评估与开发设计，适用于卫星图像中的建筑物提取与分割。为便于模型的训练和测试，数据集被划分为 17 388 个 512 px × 512 px 的图像块：训练集含 13 662 块（25 749 栋建筑，含 186 × 54 和 67 × 54 两个区域），测试集含 3 726 块（8 358 栋建筑，独立测试区 69 × 54 块）。此划分策略确保了模型在未见过的测试数据上得到性能评估，能够真实反映模型的泛化能力。

4.2 评价指标

在本研究中，为评估模型性能，通过精准率、召回率、交并比等指标反映了模型在不同方面的分割质量。

精确率 (Precision) 是指模型预测为正类的像素中实际为正类的比例，用于衡量模型预测结果的准确性。精确率的计算公式为：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$

式中：TP 表示真阳性像素（模型正确预测为正类的像素数）；FP 表示假阳性像素（模型错误预测为正类的像素数）。精确率越高，模型在预测正类时的误判越少，从而具有较高的预测准确性。

召回率 (Recall)^[12]，又称灵敏度 (sensitivity) 或阳性率 (true positive rate)，指实际为正类的像素中被模型正确识别为正类的比例。主要用于衡量模型的漏检率，指在所有真实正类像素中，模型能够正确识别出的比例。召回率的计算公式为：

$$\text{Recall} = \frac{TP}{TP + FN} \quad (10)$$

式中：FN 表示假阴性像素（模型错误预测为负类的实际正类像素数）。召回率越高表明在识别正类像素方面表现越好，漏检的可能性更小。

交并比 (intersection over union, IoU) 是计算预测分割区域与实际分割区域的交集与并集的比值，评价模型分割结果与真实标注区域垂香程度的指标。IoU 的计算公式为：

$$\text{IoU} = \frac{\text{预测区域与真实区域的交集}}{\text{预测区域与真实区域的并集}} = \frac{TP}{TP + FP + FN} \quad (11)$$

IoU 提供了一个综合性的准确度比例，能够有效评价模型对每个类别的分割效果。

平均交并比 (mean IoU, mIoU) 是在多类别分割任务中，对各类别 IoU 的平均值。mIoU 是衡量模型整体分割性能的重要指标，特别是在多类遥感图像分割任务中具有广泛应用。其计算公式为：

$$mIoU = \frac{1}{N} \sum_{i=1}^N IoU_i \tag{12}$$

式中：N 为类别数；IoU_i 为第 i 类的 IoU。mIoU 反映了模型在所有类别上的平均分割准确性 是衡量模型泛化能力和整体分割表现的关键指标。

这些评价指标为遥感图像分割模型的性能提供了全面的衡量标准，帮助研究人员从多角度评估模型的优劣，进而指导模型的改进和优化。

4.3 实验设置

实验硬件采用 Xeon Bronze 3104 CPU、128 GB 内存及双 TITAN XP 显卡，基于 Ubuntu 22.04 系统和 PaddleRS 1.0 框架（PaddlePaddle 2.4）。训练配置采用 AdamW 优化器（学习率 0.000 4，批量 32），结合线性衰减、EMA 和 warmup 策略，完成 100 个 epoch 训练。同时为了数据增强，采用了多尺度随机裁剪、几何变换（翻转 / 旋转）、色彩扰动（模糊 / 抖动）和影像交换方法，有效提升模型鲁棒性与泛化能力。

4.4 实验结果分析

表 1 展示了 MST-ViT 各规模在不同配置下的性能表现。随着模型规模从 MST-ViT-T 到 MST-ViT-H 逐渐增大，通道数、块数、注意力头数、参数量和 FLOPs 也随之增加，带来了 mIoU 的显著提升，从 36.4% 提高到 42.4%。这表明，随着模型的扩展，其在遥感图像分割任务中的表现更加出色，能够提取更丰富的特征。但性能的提升也伴随着计算复杂度的增加，因此用户可以根据具体需求在性能和计算资源之间进行权衡。

表 2 展示了不同位置编码方式对模型性能的影响。从结

果可以看出，相对于没有位置编码（No pos）的情况，加入绝对位置编码（Abs. pos）和相对位置编码（Joint rel. pos）都能略微提升 mIoU 值，尤其是联合相对位置编码的效果最佳，达到了 41.2%。此外，分解的相对位置编码（Decomposed rel. pos）虽然在参数量和计算复杂度上有所减少，但 mIoU 稍有下降，说明不同位置编码方式的选择需要在模型复杂度与性能之间进行权衡。

表 2 不同位置编码对比

Positional embeddings	Params/10 ⁶	FLOPS/10 ⁹	mIoU/%
No pos	66.3	96.6	40.8
Abs. pos	66.4	97.0	40.9
Joint rel.pos	70.5	107.2	41.2
Decomposed rel. pos	66.6	97.6	41.0
Abs. + dec. rel. pos	66.9	98.9	41.2

表 3 分析了不同残差池化策略对模型性能的影响。表格显示，当使用残差池化（X Residual）后，mIoU 从 39.5% 提升到了 40.2%，表明这一策略有助于增强模型的特征提取能力。当进一步结合 Q/K 残差（Q/K Residual）与池化操作时，mIoU 值继续提升，最终在结合了全部残差和池化策略后，mIoU 达到 41.2%，与最佳位置编码的效果相当。这表明，合理设计的残差池化策略能够有效提升模型的分割性能。

表 3 不同残差池化策略对模型性能的影响

Residual Pooling	Params /10 ⁶	FLOPS /10 ⁹	mIoU /%
w/o	61.0	86.6	39.5
X_Residual	63.9	92.5	40.2
X_Residual + full Q/K Residual	66.7	95.6	40.7
X_Residual + Q/K Pooling	66.9	96.9	41.0
X_Residual+full Q/K Pooling + Q/K Residual	66.9	98.9	41.2

从表 4 结果可见，MST-ViT-L 在遥感图像分割任务中展

表 1 MST-ViT 各规模性能对比

Model	Channels	Blocks	Heads	Param/10 ⁶	FLOPs/10 ⁹	mIOU/%
MST-ViT-T	[96,192,384,768]	[1,2,5,2]	[1,2,4,8]	58.4	85.4	36.4
MST-ViT-S	[96,192,384,768]	[1,2,11,2]	[1,2,4,8]	61.3	88.5	38.4
MST-ViT-B	[96,192,384,768]	[2,3,16,3]	[1,2,4,8]	63.4	92.4	40.1
MST-ViT-L	[144,288,576,1152]	[2,6,36,4]	[2,4,8,16]	66.9	98.9	41.2
MST-ViT-H	[192,384,768,1536]	[4,8,60,8]	[2,4,8,16]	72.5	105.4	42.4

现出显著优势。在模型复杂度与计算效率方面，MST-ViT-L 的参数量为 66.9×10^6 ，虽非最小，但仍然保持在合理范围内，比 FCN 和 PSPNet 稍大，接近 Deeplab V3+。计算复杂度方面，MST-ViT-L 的 FLOPs 为 98.9×10^9 ，仅略高于 SegFormer (96.4×10^9)，远低于 ResNet-101 架构的 FCN 和 PSPNet。同时，其推理速度达 15.9 帧/s，保持较高的实时性。最突出的是，MST-ViT-L 在 mIoU 指标上达到 41.2%，为所有模型中最高，表明其在分割精度和鲁棒性上的卓越性能，尤其适用于遥感图像分割的复杂场景。从对比结果来看，MST-ViT-L 在计算复杂度和推理速度之间取得良好平衡，实现最优 mIoU 表现，成为兼具高效性与精度的理想选择。

表 4 与其他分割模型对比

Model	Encoder	Params	Flops	FPS	mIoU
		/10 ⁶	/10 ⁹	/(帧·s ⁻¹)	%
FCN ^[13]	ResNet-101	70.2	280.2	14.8	34.8
PSPNet ^[14]	ResNet-101	69.5	264.1	15.6	36.7
HRNet	—	63.6	223.8	16.4	37.2
Deeplab V3+	ResNet-101	64.7	201.6	17.6	36.9
SegFormer	MiT-B4	64.1	96.4	16.2	38.4
MST-ViT-L	—	66.9	98.9	15.9	41.2

4.5 实验效果展示

经测试结果表明，在数据集上，MST-ViT 对建筑物轮廓的捕捉更为精准，尤其在复杂背景下的锯齿状边缘（如屋顶与道路交界处）分割更平滑，同时，MST-ViT 在面对阴影、植被遮挡等干扰因素，MST-ViT 仍能保持稳定的分割性能。相较于 Deeplab v3+ 与 SegFormer，MST-ViT 的分割结果更贴近真实标注（Ground Truth），如图 3 所示。




图 3 测试实验效果

5 结论

本研究提出了一种针对高分辨率遥感图像分割的多尺度视觉 Transformer (MST-ViT) 模型，来缓解计算复杂度和内存占用的问题。通过引入平移不变位置嵌入，增强了模型对空间位置信息的感知能力，同时还采用残差池化连接，在降低计算量的同时尽可能保留细节信息。通过实验结果表明，MST-ViT 模型在多尺度特征提取和细节保持方面相较于现有方法具有一定的优势，并在计算效率与分割精度之间取得了较好的平衡，经测试结果证实，MST-ViT 模型在遥感图像分割任务中表现良好，为高效、高精度的遥感影像分析提供了一种可行的解决方案，并为未来 Transformer 在遥感领域的应用提供了有益的参考。

参考文献:

[1] 余民民. Transformer 模型在遥感图像分割中的性能研究 [D]. 郑州: 河南大学, 2023.

[2] 高梓雕. 基于生成对抗网络的数据样本生成技术研究 [D]. 新乡: 河南师范大学, 2023.

[3] 陈聪. 基于深层网络的城市街道场景的语义分割的方法研究 [D]. 西安: 西安电子科技大学, 2019.

[4] 周显亨, 刘深波, 贺皇, 等. 基于多尺度特征融合的遥感变化检测网络 [J]. 激光与光电子学进展, 2025, 62(10): 356-365.

[5] 李永辉, 赵耀, 加小红, 等. CNN 与 Transformer 协同的多模态边缘检测网络 [J/OL]. 计算机工程与应用, 1-12 [2025-03-11]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20250225.1638.020.html>.

[6] 邹有才. 基于多尺度残差注意力及视觉 Transformer 的自然场景表情识别研究与实现 [D]. 南昌: 江西师范大学, 2024.

[7] 曹冠华, 党建武, 杨景玉. 基于改进 SegFormer 的光伏组件分割算法 [J]. 太阳能学报, 2025, 46(2): 425-432.

[8] 闫林, 王磊, 艾孜麦提·艾尼瓦尔, 等. 基于多尺度风格自适应的手写维文识别模型 [J]. 计算机工程与设计, 2024, 45(9): 2749-2756.

[9] 熊岚堃, 张桂梅, 刘晖群, 等. 结合轴向增强 Transformer 与 CNN 双编码的医学图像分割方法 [J/OL]. 计算机辅助设计与图形学学报, 1-13 [2025-03-11]. <http://kns.cnki.net/kcms/detail/11.2925.TP.20250206.1623.033.html>.

[10] 蔡俊民, 梁正友, 欧阳正超, 等. 基于多尺度融合与残差双注意力的点云分类 [J]. 昆明学院学报, 2024, 46(6): 67-78.

[11] 香晏, 赵响, 黄军韬. 一种基于残差连接的 Swin Transformer 增强型联合编码架构设计 [J]. 无线电工程, 2025, 55(5): 905-912.

基于改进灰狼算法的无线传感网络节点覆盖优化方法

刘 凯¹ 李 婷¹
LIU Kai LI Ting

摘 要

无线传感网络部署在动态环境中时,节点位置或环境条件可能随时间变化,节点位置的调整需要综合考虑覆盖范围、节点密度和网络连通性等多重因素,这使得节点覆盖优化问题涉及高维解空间。传统灰狼算法采用随机初始化时,初始解集分布不均,优化过程容易陷入局部最优,导致覆盖率下降。为此,文章提出一种基于改进灰狼算法的无线传感网络节点覆盖优化方法。根据区域覆盖原则和节点均匀分布要求,计算传感器扇形的覆盖范围半径并确定扇形内节点坐标位置,设计初始部署方案,并利用覆盖率指标筛选初始方案,确保初始解集的质量。采用改进的灰狼算法对选定的初始方案进行优化。在算法初始化阶段,引入 Tent 混沌映射技术确保初始解集的均匀分布,避免算法陷入局部最优。在迭代过程中,模拟狼群的捕食行为更新节点位置,实现节点在网络区域内的精细调整,逐步逼近最优解。引入莱维飞行机制实现大范围的跳跃搜索,增强全局搜索能力。通过预设的适应度函数评估每个灰狼个体的适应度值,指导算法的搜索方向。在达到最大迭代次数后,输出网络节点最优部署方案。实验结果表明,该方法能够显著提升无线传感网络的节点覆盖率,实现更加均匀且全面的网络覆盖,具有实际应用价值。

关键词

无线传感网络;节点覆盖优化;改进灰狼算法;最优部署方案;覆盖率

doi: 10.3969/j.issn.1672-9528.2025.07.031

0 引言

无线传感器网络作为一种关键的信息采集和处理技术,在多个领域展现出广泛应用潜力。然而,节点覆盖率低一直是制约其性能提升的关键因素。低覆盖率会导致监测区域出现盲区,影响数据准确性和完整性,同时造成资源浪费和能效降低。针对这一问题,许多学者展开了深入研究,提出了多种优化策略,但仍存在一定的局限性。其中,基于改进烟花算法的无线传感器网络覆盖优化策略,通过引入烟花算法

的爆炸搜索机制,对节点的位置进行优化调整,提高了节点的覆盖率^[1]。在动态环境中,节点位置和环境条件不断变化,爆炸搜索的范围可能无法适应这种变化,导致新解生成局限于局部区域,难以跳出局部最优。基于邻居信息的无线传感网络节点覆盖优化方法,通过利用邻居节点的位置信息,对节点的部署进行调整,实现更加均匀的覆盖^[2]。但该方法主要依赖邻居节点的位置信息进行局部调整,缺乏全局搜索能力,在高维解空间中容易陷入局部最优。基于多策略改进蝴蝶优化算法的无线传感网络节点覆盖优化,通过结合多种优化策略,对蝴蝶优化算法进行了改进,提高了节点的搜索效

1. 郑州工商学院信息工程学院 河南郑州 450000

[12] 沈涛,张秀再,许岱.改进 RT-DETR 的遥感图像小目标检测算法[J/OL]. 计算机科学,1-13[2025-03-11].<http://kns.cnki.net/kcms/detail/50.1075.tp.20250307.0953.002.html>.

[13] 宋佳.基于 FCN-DARG 的区域举证图斑和恢复属性提取技术[J]. 北京测绘,2024,38(12):1734-1738.

[14] 王元新,吕新荣,任鹏.基于 PSPNet 和 DBSCAN 的浒苔遥感影像快速解译方法设计[J]. 遥测遥控,2025,46(2):100-108.

【作者简介】

刘明阳(2004—),男,辽宁朝阳人,本科在读,研究方向:嵌入式系统开发、深度学习, email: lmy1211lmy@163.com。

陈美琳(2002—),女,河北沧州人,本科,研究方向:电子信息工程, email: cml_0509@163.com。

巩荣芬(1979—),通信作者(email: chu52_2004@163.com),女,辽宁鞍山人,博士研究生,副教授,研究方向:模式识别与智能系统。

(收稿日期: 2025-03-11 修回日期: 2025-07-07)