

面向HSI与LiDAR融合分类的决策-学习-修正网络

王浩宇^① 刘诺菲^① 程玉虎^① 刘晓敏^① 王雪松^{*①}

^①(中国矿业大学信息与控制工程学院, 江苏徐州 221116)

摘要: 高光谱图像与LiDAR在光谱表征和空间结构刻画方面具有天然互补性, 其有效融合被认为是提升遥感地物分类性能的重要途径。然而, 现有方法多将融合过程建模为固定映射下的一次性静态聚合, 隐含地假设同一融合策略能够适用于不同区域, 因而难以应对遥感影像中普遍存在的空间异质性和样本复杂性。为此, 本文提出一种决策-学习-修正网络, 将传统静态融合重构为面向局部上下文的序列决策过程使模型能够在连续交互中学习上下文依赖的自适应融合策略。针对关键样本易被忽视的问题, 构建关键样本导向采样模块, 依据样本决策困难度提高复杂区域样本的训练参与度。针对融合动作可能破坏模态特性的问题, 设计模态保真约束机制, 对不合理动作进行修正, 以保证融合特征质量。实验结果表明, 所提方法在Houston2013、Trento和MUUFL三个基准数据集上的总体精度分别提升0.82%、0.38%和1.76%, 验证了该方法在复杂场景下的有效性与优越性。

关键词: 高光谱图像; LiDAR; 多模态融合; 序贯决策优化; 分类

中图分类号: TP18

文献标识码: A

文章编号: 1009-5896(2026)00-0001-12

DOI: 10.11999/JEIT260362

CSTR: 32379.14.JEIT260362

1 引言

近年来, 随着空间信息获取技术的快速发展和遥感传感器性能的不断提升, 多模态遥感数据的融合与分析逐渐成为地物精细分类、环境监测以及地表特征识别等任务的核心研究方向^[1-3]。高光谱图像(Hyperspectral Images, HSI)与LiDAR因在光谱表征和空间结构刻画上的互补性, 已成为遥感地物分类中的重要数据来源。HSI能够捕获连续窄波段光谱信息, 为地物材料识别提供细粒度光谱表征^[4-6], LiDAR则通过主动测距获取高精度高程信息, 能够有效反映地物的空间形态特征^[7-8]。因此, 如何协同利用HSI的光谱判别能力与LiDAR的结构感知能力, 已成为提升复杂场景分类性能的关键问题之一。

然而, 模态互补并不意味着可以通过单一融合规则稳定地获得性能增益。现有主流方法多采用注意力加权^[9-11]或门控调制^[12]实现特征聚合, 本质上是通过一次性学习固定映射来完成多模态融合。这类方法隐含地假设存在一种对所有像元和区域均有效的统一融合策略, 但该假设难以满足遥感场景中普遍存在的空间异质性。对于植被等光谱特征占主

导的区域, 过多引入结构信息可能干扰原有光谱判别性。而对于建筑等结构特征更突出的区域, 过度平滑的光谱融合又可能削弱关键几何细节。因此, 静态融合方法难以根据局部上下文差异灵活调整模态贡献, 其分类性能在复杂区域中往往受到限制。

为突破静态融合方法的局限, 需要将多模态特征融合从固定映射下的一次性聚合, 转化为随局部状态持续调整的序列建模过程。与传统方法不同, 在该过程中, 模型不再依赖单一融合规则完成特征组合, 而是根据当前上下文动态决定不同模态信息的保留、抑制与重组方式。进一步地, 单步融合动作的有效性不仅取决于当前特征表达, 还应结合其对后续状态演化及最终分类结果的长期影响进行评估。因此, 将多模态融合建模为序列决策过程, 有望更合理地刻画复杂场景下的动态模态协同关系。目前, 强化学习在遥感多模态融合中的探索如马尔可夫边缘解耦融合网络(Markov Edge Decoupled Fusion Network, MEDFN)^[13]利用马尔可夫决策像素连边, 未涉及到多模态融合方面。

基于上述分析, 在将多模态融合视为序列决策过程之后, 关键问题转化为: 如何依据当前融合状态生成合理动作, 并评估该动作对后续融合演化及最终分类结果的长期影响。Actor-Critic框架为此提供了合适的建模方式: Actor负责生成当前状态下的融合动作, Critic负责评估该动作的长期价值, 从而实现跨时间步的信用分配, 使模型能够学习上下文依赖的动态融合策略。尽管如此, 强化学习若直接迁移到该任务中仍存在明显局限。一方面, 遥感影像的信息分布呈现显著的空间不均性(如图1所

收稿日期: 2026-03-30; 改回日期: 2026-07-03; 网络出版: 2026-07-14

*通信作者: 王雪松 wangxuesongcumt@163.com

基金项目: 国家自然科学基金(62303468), 徐州科技项目(KC2025123), 国家自然科学基金(62373364, 62573416, 62303469)

Foundation Items: National Natural Science Foundation of China (62303468), Science and Technology Program of Xuzhou (KC2025123), National Natural Science Foundation of China (62373364, 62573416, 62303469)

示), 类别边界像元和跨模态异质区域等关键样本数量有限, 却对分类性能具有更高影响。传统经验回放通常对样本进行近似均匀采样, 导致关键样本参与训练的频率不足, 难以支撑模型在复杂区域形成稳定判别。另一方面, 强化学习在追求累计回报的过程中可能学习到破坏模态特性的动作, 例如抑制某一模态的关键判别信息或引入不一致的跨模态干扰, 从而削弱融合特征质量。现有方法中的策略约束大多服务于训练稳定性^[14], 并未显式面向模态保真进行设计, 因此难以满足HSI与LiDAR融合分类的任务需求。

针对上述问题, 本文提出一种面向HSI与LiDAR融合分类的决策-学习-修正网络。在Actor-Critic框架下, 该方法将多模态特征融合建模为序列决策过程, 通过跨时间步的价值评估学习上下文依赖的融合策略。为增强模型对复杂区域的判别能力, 引入关键样本导向采样模块, 提高关键样本在训练过程中的参与度。为避免动态融合过程中模态特性受损, 构建模态保真约束机制, 对不合理融合动作进行修正, 从而提升融合特征质量。通过上述设计, 模型能够更充分地挖掘HSI与LiDAR的互补信息, 并提升复杂场景下的分类精度。本文的主要贡献如下:

(1) 提出决策-学习-修正网络, 将传统静态融合重构为面向局部上下文的序列决策过程使模型能够在连续交互中学习上下文依赖的自适应融合策略。

(2) 设计价值引导策略优化机制, 通过Actor网络生成动作, 并由Critic网络评估该动作对长期回报的贡献, 完成多步决策的信用分配与策略优化。

(3) 提出关键样本导向采样模块, 通过模态保

真损失动态量化每个样本的决策困难度, 强制模型聚焦于关键样本的学习。

(4) 提出模态保真约束机制, 通过实时评估动作的有效性, 在动态融合过程中保护各模态特性进而提高融合特征质量。

2 模型结构

2.1 决策-学习-修正网络

网络训练流程如图2所示, 主要包括如下三个阶段:

阶段 I: 将两模态数据分别进行特征提取, 首先, 使用 1×1 卷积提取基础特征。然后, 将其输入多尺度卷积块, 通过并行使用4组不同卷积核同时捕获不同尺度的空间特征。其次, 采用金字塔池化模块在多个分辨率聚合上下文信息。最后, 通过卷积块融合各级特征, 得到包含丰富光谱-空间信息的高光谱图像特征 F_{HSI} 和精确高程-结构信息的LiDAR特征 F_{LiDAR} 。

阶段 II: 首先, 将得到的 F_{HSI} 和 F_{LiDAR} 拼接为当前状态 s_t 输入至Actor网络。接着, Actor网络基于该状态生成原始动作。同时, 基于模态保真约束机制计算得到的约束向量 C_t 评估该动作的有效性, 并通过子空间投影将其修正。其次, 修正后的动作被用于与环境交互, 获得下一时刻的状态与分类奖励, 并将其与当前状态共同构成完整的经验条 $(s_t, a_t, r_t, s_{t+1}, C_t)$ 。接着, 每条经验根据其约束违背程度被赋予优先级并存储至关键样本导向采样模块, 以增强关键样本在训练过程中的贡献。同时, Critic网络利用可行动作评估其长期回报, 并将价值信号用于Actor的策略梯度更新, 从而推动融合




图1 遥感数据的信息密度不均(以Houston2013数据集为例):采用 7×7 像素滑动窗口遍历遥感影像, 计算每个局部区域的熵值; 基于全部局部熵值开展统计分析并生成直方图, 同时将局部熵值以伪彩色映射至影像对应空间位置, 得到如下子图: (a)全局信息密度分布: 为局部熵值的统计直方图。其分布呈左高右低的长尾特征: 约80%窗口的熵值集中于1.5~2.5区间, 熵大于3的高信息窗口占比约5%, 此类区域对应类别边界像元、跨模态异质区域等关键样本。(b)局部信息熵: 为局部熵的伪彩色渲染图(颜色亮度与熵值正相关, 亮度越高代表区域纹理越复杂、信息越丰富), 图中四个区域局部信息熵直观呈现了遥感影像信息密度的空间不均匀性。




图2 决策-学习-修正网络

策略的持续优化。最终，采用软更新机制同步更新策略网络与双Q目标网络，确保融合策略在训练过程中稳定演化并逐步收敛。

阶段III：应用前面阶段学习到的最优融合策略执行最终分类。

2.2 特征提取

为从高光谱图像与激光雷达数据中提取互补特征，设计多模态特征嵌入模块。采用并行架构处理双模态输入，通过多尺度卷积与全局上下文聚合生成判别性特征表示。

对于高光谱图像分支，首先输入 $\mathbf{X}_{\text{HSI}} \in \mathbb{R}^{s \times s \times c_1}$ 通过 1×1 卷积提取光谱特征 $\mathbf{F}_{\text{spe}} \in \mathbb{R}^{s \times s \times d}$ ，随后通过多尺度卷积块捕获多尺度空间特征 $\mathbf{F}_{\text{HSI}}^{\text{ms}}$ ：

$$\mathbf{F}_{\text{HSI}}^{\text{ms}} = \text{MultiScaleConv}(\mathbf{F}_{\text{spe}}) \quad (1)$$

并行使用 1×1 、 3×3 、 5×5 和 7×7 卷积核，使网络具备尺度不变性。接着，采用金字塔池化模块 (Pyramid Pooling Module, PPM) 在多个分辨率 (1×1 、 2×2 、 3×3 和 6×6) 聚合全局上下文信息得到金字塔池化后的特征 $\mathbf{F}_{\text{HSI}}^{\text{ppm}}$ ：

$$\mathbf{F}_{\text{HSI}}^{\text{ppm}} = \text{PPM}(\mathbf{F}_{\text{HSI}}^{\text{ms}}) \quad (2)$$

最后，通过卷积块连接光谱特征和空间特征，得到最终的高光谱图像特征 $\mathbf{F}_{\text{HSI}} \in \mathbb{R}^{s \times s \times d_1}$ ：

$$\mathbf{F}_{\text{HSI}} = \text{FusionBlock}(\mathbf{F}_{\text{spe}}, \mathbf{F}_{\text{HSI}}^{\text{ppm}}) \quad (3)$$

LiDAR分支采用相同架构，输入 $\mathbf{X}_{\text{LiDAR}} \in$

$\mathbb{R}^{s \times s \times c_2}$ ，依次经卷积块、多尺度卷积块和PPM处理，输出LiDAR特征 $\mathbf{F}_{\text{LiDAR}} \in \mathbb{R}^{s \times s \times d_2}$ 。得到包含丰富信息的高光谱图像和LiDAR特征，为后续自适应融合奠定基础。

2.3 融合网络构建

2.3.1 序贯决策问题定义

现有融合方法大多使用一步到位的融合范式，忽略了融合策略是一个随时间和任务进展演化的过程。提出价值引导策略优化机制将其融合建模为序贯决策任务，旨在通过逐步优化融合策略。序贯框架通过将复杂融合任务分解一系列连续时间步，使模型能根据每一时间步的融合结果自主调整后融合策略，从而更有效地探索解空间以得到最优策略。

具体而言，智能体作为融合策略的动态调整者，在每个时间步接收环境状态，经Actor网络生成动作，Critic网络则评估该动作对分类结果的长期价值。智能体通过与环境持续交互，学习最大化累积奖励的融合策略，最终实现分类性能最优化。

基于上述思想，该融合过程可形式化为马尔可夫决策过程，定义为四元组 (S, A, P, R) ：

(1) 状态空间 (S)：状态空间包含了整个环境的描述信息，是智能体决策的基础。在第 t 个时间步，智能体从环境获取状态向量 s_t ：

$$s_t = [\mathbf{F}_{\text{HSI}}, \mathbf{F}_{\text{LiDAR}}] \quad (4)$$

其中， $\mathbf{F}_{\text{HSI}}$ 和 $\mathbf{F}_{\text{LiDAR}}$ 分别是提取到的高光谱图像和

LiDAR特征, 状态捕获了当前样本的特征分布, 为智能体决策提供了基础信息。

(2)动作空间(A): 动作空间决定了智能体可采取的行为, 即每种模态的不同融合权重。策略网络(Actor)处理状态向量, 输出动作分布参数 $\mu_\theta(s_t)$ 、 $\sigma_\theta(s_t)$ 和预测的约束值 c_θ :

$$\mu_\theta, \sigma_\theta, c_\theta = \pi_\theta(s_t) \quad (5)$$

其中, π_θ 是参数为 θ 的策略网络函数。策略网络采用了通过参数化的高斯分布表示策略, 模型能够同时进行探索和利用, 适应不同地物类型的特征差异。

通过重参数化技巧生成随机动作 a_t :

$$a_t = \text{Tanh}(\mu_\theta(s_t) + \sigma_\theta(s_t) \odot \varepsilon) \varepsilon \sim \mathcal{N}(0, I) \quad (6)$$

其中, ε 是标准正态分布中采样的随机噪声, $\odot$ 表示逐元素乘积, Tanh 函数将输出压缩到 $[-1, 1]$ 区间, 确保生成动作在有效范围内。

(3)转移概率(P): 状态转移函数 $P(s_t, a_t) \rightarrow s_{t+1}$ 表示如何从当前状态 s_t , 执行动作 a_t 后转移到新状态 s_{t+1} 。

(4)奖励函数(R): 奖励函数是判定智能体行为好坏的指标, 即反应最终分类结果。为了更好的让网络学习到最优融合策略, 我们构建一个能够反映融合策略质量、引导智能体做出合理决策的奖励函数。该奖励函数由分类奖励和质量奖励组成。增强智能体在对每一步动作(融合策略)好坏的判别进而朝着最大化累计回报(即最高分类精度)的方向前进。总奖励 R_t 由分类奖励 R_1 和质量奖励 R_2 组成:

$$R_t = R_1 + \lambda \cdot R_2 \quad (7)$$

其中, λ 为平衡参数, 控制分类性能与特征质量的权衡。

分类奖励 R_1 关注分类性能, 直接反映当前融合策略的有效性:

$$R_1 = 2 \cdot p(y_{\text{true}}) - 1 + 0.5 \cdot 1[\hat{y} = y_{\text{true}}] - 0.5 \cdot 1[\hat{y} \neq y_{\text{true}}] \quad (8)$$

其中, $p(y_{\text{true}})$ 是目标类别的预测概率, 取值范围 $[0, 1]$, $1[\cdot]$ 是指示函数, 正确分类获得额外奖励, 错误分类则受到惩罚。我们同时考虑了预测的置信度和正确性, 鼓励模型生成高置信度的正确预测。

质量奖励 R_2 评估特征保持性能, 关注约束满足度的变化趋势:

$$R_2 = \bar{L}_k^{\text{recent}} - L_k \quad (9)$$

其中, $\bar{L}_k^{\text{recent}}$ 是前五次迭代的模态保真约束机制计算的四维约束的平均损失, 与当前损失 L_k 的差值作为趋势奖励项。若差值为正, 表明约束违反程度持

续下降(融合质量改善), 给予正向激励。若差值为负, 则惩罚策略退化, 强制智能体回退至优解邻域。

通过上述MDP建模, 融合任务转化为智能体与环境的序贯交互过程。每次迭代从关键样本导向采样模块中采样, 并执行策略更新, 逐步收敛至最优融合策略。通过关键样本导向采样模块与模态保真约束机制(详见第2.3.2和2.4节)进一步强化对关键样本的学习能力和保证动作的有效性。

2.3.2 关键样本导向采样模块

在特征融合过程中, 传统经验回放对所有样本同等采样, 导致关键样本学习度不足。提出关键样本导向采样模块, 以模态保真损失为核心, 通过量化每条经验的优先级增加网络对关键样本的学习度, 持续提升融合特征质量。具体实现如下:

首先, 完成一次环境交互后, 经验元组 $(s_t, a_t, r_t, s_{t+1}, done, C_t)$ 被存入经验池。

然后, 将样本的决策困难度具体量化为序列决策中的模态保真约束损失。约束损失越大, 表明当前的融合动作对模态特性的破坏越严重, 网络学习最优融合策略的决策困难度越高。由此, 基于约束损失计算经验优先级来显式表征这一决策困难度:

$$p_t = \alpha_1 \cdot L_{\text{spec}} + \alpha_2 \cdot L_{\text{LiDAR}} \quad (10)$$

其中, α_1 和 α_2 是两类主要约束的权重系数。经验的决策困难度经过量化计算得到的优先级 p_t , 决定了该经验在后续采样中被选中的概率。

为了基于决策困难度(即经验优先级)合理提高关键样本的训练参与度, 采样概率与优先级的 α_3 次方成正比:

$$P(i) = p_i^{\alpha_3} / \sum_j p_j^{\alpha_3} \quad (11)$$

其中, α_3 控制采样的偏好程度。 α_3 为0时退化为均匀采样, α_3 为1时完全按照优先级采样。在从关键样本导向采样模块采样批次数据用于网络更新时, 优先级选择学习如何处理困难样本, 加速模型学习最优融合权重。

最后, 为避免过度聚焦于高优先级样本而导致模型对其他样本学习不足, 引入重要性采样技巧对采样过程进行修正, 确保采样的代表性与多样性:

$$\omega_i = \left(\frac{1}{N} \cdot \frac{1}{P(i)} \right)^\beta \quad (12)$$

其中, ω_i 是样本 i 的重要性采样权重, N 是经验缓冲区大小, β 从初始值逐渐增加到1, 在训练初期允许更多探索, 后期减少偏差确保收敛。

2.3.3 网络更新

基于关键样本导向采样模块提供的优先级经验

样本, 网络参数通过Actor-Critic网络实现闭环协同优化。首先, Critic采用双Q网络架构, 目标值计算为:

$$y = R + \gamma(1 - d) \left[\min_{j=1,2} (Q_{\phi_j}(s', a') - \alpha \log \pi_{\phi}(a'|s')) \right] \quad (13)$$

其中, γ 是折扣因子, d 是终止标志, Q_{ϕ_j} 是目标Q网络, $a' \sim \pi_{\phi}(\cdot|s')$ 是从策略中采样的下一动作, α 是温度参数, 控制熵正则化强度。预测的价值等于即时获得的奖励, 加上未来可能获得的折扣奖励(如果任务未结束)。

其次, Q网络通过最小化预测值与目标值之间的差异来学习, Q网络损失函数为:

$$L_Q(\phi) = E_{(s,a,r,s',d) \sim D} [\omega_i \cdot (Q_{\phi}(s, a) - y)^2] \quad (14)$$

其中, ϕ 是Actor网络的可训练参数, ω_i 是重要性采样权重, 纠正由优先级采样引入的偏差。

然后, Actor网络负责生成新的融合权重决策, 通过最大化预期Q值同时保持适当的决策随机性来学习。策略网络同时学习最优融合权重和约束预测:

$$L_{\pi}(\phi) = E_{s \sim D} [\alpha \log \pi_{\phi}(a|s) - \min_{i=1,2} Q_{\theta_i}(s, a)] \quad (15)$$

$$L_c(\phi) = E_{s \sim D} \left[\|c_{\text{pred}} - c_{\text{target}}\|^2 \right] \quad (16)$$

$$L_{\text{total}}(\phi) = L_{\pi}(\phi) + \lambda_c \cdot L_c(\phi) \quad (17)$$

其中, c_{pred} 是Actor网络预测的约束值, c_{target} 是目标约束值, λ_c 是约束损失权重。策略损失 L_{total} 包含两部分: 策略熵与Q值的加权和 L_{π} , 以及约束预测损失 L_c 。

温度参数 α 通过最小化以下损失自动调整:

$$L_{\alpha}(\alpha) = -E_{a \sim \pi_{\phi}} [\alpha \cdot (\log \pi_{\phi}(a|s) + \mathbf{H}_{\text{target}})] \quad (18)$$

其中, $\mathbf{H}_{\text{target}}$ 是目标熵值, 通常设置为动作空间维度的负值(即 $-\dim(A)$)。温度参数能够自适应调整, 在策略熵低于目标值时增大(鼓励更多探索), 在策略熵高于目标值时减小(鼓励更多利用)。

最后, 目标Q网络通过软更新机制更新:

$$\theta'_i \leftarrow \tau \theta_i + (1 - \tau) \theta'_i \quad (19)$$

其中, θ 为目标Q网络的参数, τ 是软更新系数, 控制目标网络跟踪当前网络的速度。缓慢更新机制能够提高训练的稳定性, 防止Q值估计的剧烈波动。

2.4 模态保真约束机制

模态保真约束机制构建了全面的融合特征质量评估与动作修正机制, 以获得高质量融合特征。通过在每个批次、每个样本上实时工作, 确保每次融

合操作都能满足基本的约束要求, 以此做到实时修正融合动作以保证动作的有效性。

首先, 在进行模态保真约束评估之前, 先基于智能体当前输出的决策动作来生成初步的融合特征 $\mathbf{F}_{\text{fused}}$ 。具体而言, 策略网络输出的连续动作向量 $a_{t'}$ 承载了通道级的注意力权重信息。本文将 $a_{t'}$ 沿通道维度对称拆解为对应于高光图像的分量 $a_{t', \text{HSI}}$ 和对应于激光雷达的分量 $a_{t', \text{LiDAR}}$, 随后通过通道加权与特征拼接生成当前步的融合特征, 其数学表达为:

$$\mathbf{F}_{\text{fused}} = (a_{t', \text{HSI}} \otimes \mathbf{F}_{\text{HSI}}) \oplus (a_{t', \text{LiDAR}} \otimes \mathbf{F}_{\text{LiDAR}}) \quad (20)$$

其中, $\mathbf{F}_{\text{HSI}}$ 和 $\mathbf{F}_{\text{LiDAR}}$ 分别表示由多尺度特征提取模块输出的高光图像与LiDAR深层特征表示。 $\otimes$ 表示Hadamard乘积, $\oplus$ 表示在通道维度上的特征拼接操作。在得到 $\mathbf{F}_{\text{fused}}$ 后, 本文设计光谱保真度 L_{spec} 、特征一致性 L_{LiDAR} 、结构保持 L_{struct} 和分辨率匹配 L_{res} 四类融合特征评估指标, 全面评估融合质量:

光谱保真度基于光谱角度映射(Spectral Angle Mapper, SAM)评估融合特征对高光图像特征的保真度:

$$L_{\text{spec}} = \frac{1}{90^\circ} \cdot \arccos \left(\frac{\langle \mathbf{F}_{\text{HSI}}, \mathbf{F}_{\text{fused}} \rangle}{\|\mathbf{F}_{\text{HSI}}\| \cdot \|\mathbf{F}_{\text{fused}}\|} \right) \cdot \frac{180^\circ}{\pi} \quad (21)$$

其中, $\langle \mathbf{F}_{\text{HSI}}, \mathbf{F}_{\text{fused}} \rangle$ 表示高光图像特征与融合特征的内积, $\|\mathbf{F}_{\text{HSI}}\|$ 和 $\|\mathbf{F}_{\text{fused}}\|$ 分别是它们的范数。光谱角度归一化到[0,1]区间, 角度越小表示融合特征与原高光图像特征之间的光谱相似性越大。

特征一致性基于归一化L2距离衡量融合特征对激光雷达空间结构的保持程度:

$$L_{\text{LiDAR}} = \frac{\|\mathbf{F}_{\text{LiDAR}} - \mathbf{F}_{\text{fused}}\|_2}{\|\mathbf{F}_{\text{LiDAR}}\|_2 + \varepsilon} \quad (22)$$

其中, $\|\mathbf{F}_{\text{LiDAR}} - \mathbf{F}_{\text{fused}}\|_2$ 是激光雷达特征与融合特征的欧几里得距离, $\|\mathbf{F}_{\text{LiDAR}}\|_2$ 是激光雷达特征的范数, ε 是小常数, 防止除零错误。归一化处理防止高值特征主导距离计算, 确保不同尺度特征的公平比较。

结构保持基于改进的结构相似性指数(Structural similarity index, SSIM)评估融合特征的空间结构保持能力:

$$L_{\text{struct}} = 1 - \frac{(2\mu_{\text{HSI}}\mu_{\text{fused}} + C_1)(2\sigma_{\text{HSI}, \text{fused}} + C_2)}{(\mu_{\text{HSI}}^2 + \mu_{\text{fused}}^2 + C_1)(\sigma_{\text{HSI}}^2 + \sigma_{\text{fused}}^2 + C_2)} \quad (23)$$

其中, μ_{HSI} 和 μ_{fused} 分别是高光图像特征和融合特征的均值, σ_{HSI} 和 σ_{fused} 是它们的标准差, $\sigma_{\text{HSI}, \text{fused}}$ 是它们的协方差, C_1 和 C_2 是稳定常数。SSIM指数考虑了亮度、对比度和结构三个方面, 确保融合后地物边界和纹理特征的完整保留。

分辨率匹配基于梯度差异计算评估融合特征的细节保持能力:

$$L_{\text{res}} = 0.7 \cdot \frac{|||\nabla \mathbf{F}_{\text{HSI}}| - |\nabla \mathbf{F}_{\text{fused}}|||}{|\nabla \mathbf{F}_{\text{HSI}}| + \varepsilon} + 0.3 \cdot \frac{|\angle \nabla \mathbf{F}_{\text{HSI}} - \angle \nabla \mathbf{F}_{\text{fused}}|}{\pi} \quad (24)$$

其中, $\nabla \mathbf{F}$ 表示特征 $\mathbf{F}$ 的梯度, $|\nabla \mathbf{F}|$ 是梯度幅度, $\angle \nabla \mathbf{F}$ 是梯度方向, 权重系数 0.7 和 0.3 反映了幅度差异相对于方向差异的重要性。第一项评估梯度幅度差异, 第二项评估梯度方向差异, 确保小尺度地物特征不被平滑或丢失。

接着, 将原始动作 a_t 投影到规范化动作空间中得到最终供执行的动作, 以生成最终的特征融合权重。具体而言, 由于策略网络采样的原始动作值无界, 本文引入 Sigmoid 函数作为连续投影算子, 将动作分量严格映射至 $[0, 1]$ 区间内:

$$a_{t'} = \sigma(a_t) = 1 / (1 + e^{-a_t}) \quad (25)$$

其中, $a_{t'}$ 表示规范化后的实际执行动作(即融合权重向量)。连续投影机制以最小的计算开销实现了对策略动作的实时约束调控, 使决策过程在保持探索性的同时避免产生破坏模态特性或偏离可行解域的动作, 从而确保融合策略在训练过程中的稳定演化与特征质量的持续改善。

2.5 分类

在推理与最终分类阶段, 转而采用经规范化投影得到的有效执行动作 $a_{t'}$ 。得到满足模态保真约束的最优融合特征 $\mathbf{F}_{\text{fused}}$ 后, 分类器网络负责将样本映射到对应的地物类别。我们设计的分类器网络包含多个组件, 以充分利用融合特征信息。

分类过程可以表示为:

$$y = C(F(\text{HSI}, \text{LiDAR})) \quad (26)$$

其中, $C(\cdot)$ 代表分类器, $F(\cdot)$ 代表融合函数, y 是预测的类别。

首先, 自适应平均池化层对融合特征进行全局空间聚合:

$$\mathbf{Z}_{\text{global}} = \text{AdaptiveAvgPool2d}(\mathbf{F}_{\text{fused}}) \quad (27)$$

其中, $\mathbf{F}_{\text{fused}} \in \mathbb{R}^{B \times C \times H \times W}$ 是融合特征, $\mathbf{Z}_{\text{global}} \in \mathbb{R}^{B \times C \times 1 \times 1}$ 是池化后的特征, B 是批次大小, C 是通道数, H 和 W 是特征图的高和宽。网络能够关注整体特性而非局部变化。

接着, 特征被展平并送入两层全连接网络:

$$\hat{y} = \text{FC}_2(\text{Dropout}(\text{ReLU}(\text{FC}_1(\text{Flatten}(\mathbf{Z}_{\text{global}}))))) \quad (28)$$

其中, FC 是全连接层, ReLU 为激活函数, Dropout 是正则化层, $\hat{y}$ 是类别得分向量。

最后, 在训练过程中, 模型使用交叉熵损失函数优化网络参数:

$$L_{\text{CE}} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{i,k} \log(\hat{y}_{i,k}) \quad (29)$$

其中, N 是样本数, $y_{i,k}$ 是样本 i 属于类别 k 的真实标签 (0 或 1), $\hat{y}_{i,k}$ 是模型预测样本 i 属于类别 k 的概率。

3 实验结果与分析

3.1 数据集

我们使用 Houston2013 数据集^[15], Trento 数据集^[16] 和 MUUFL 数据集^[17] 验证决策-学习-修正网络 (Decision Learning Correction Network, DLCN) 的性能。各数据集采集地点依次为休斯顿, 特伦托和长滩地区。数据集的训练和测试样本数量参考文献^[19]。

3.2 实验设置

为评估所提出方法的分类性能, 选择三个定量指标, 分别是总体准确率 (OA)、平均准确度 (AA) 和 kappa 系数 (Kappa)。具体而言, OA 表示正确分类的测试样本与所有测试样本的比例, 而 AA 表示所有类别的平均分类精度。Kappa 衡量了预测分类图与地面事实之间的一致性, 考虑了偶然性一致性。所有指标的值越高, 表明分类性能越好。

在训练阶段, 学习率设置为 0.0005, weight decay 设置为 0.0002, batch size 设置为 64, Trento 训练集训练了 150 个 epoch, Houston2013 和 MUUFL 数据集训练了 200 个 epoch。超参数 λ 用于权衡分类奖励与质量奖励, 在 Houston 2013、Trento 和 MUUFL 三个数据集上的最优取值分别为 0.8、1.0 和 1.0。所有实验都在一台配备了 5.70 GHz AMD Ryzen 9 9950X CPU、64GB RAM 和 RTX 4080 SUPER GPU 的计算机上进行, 实验环境为 PyTorch。选择 6 种方法进行对比实验用以验证 DLCN 的性能, 6 种方法分别为: 粗到细的高阶网络 (Coarse-to-fine High-order Network, CHNet)^[18]、深度对称融合变换器 (Deep Symmetric Fusion Transformer, DSymFuser)^[19]、多正样本匹配增强对比学习 (Multipositive Matching-enhanced Contrastive Learning, mPMCL)^[20]、马尔可夫边缘解耦融合网络 (Markov Edge Decoupled Fusion Network, MEDFN)^[13]、空间-光谱-结构特征融合网络 (Spatial-spectral-structural Feature Fusion Network, S3F2Net)^[21] 和掩蔽自注意融合网络 (Masked Self-attention Fusion Network, MSAF)^[22]。分类结果如图 3-5 和表 1-3 所示。

3.3 分类结果和分析

从表1-3和图3-5可以看出：

(1)本文提出的DLCN在整体性能上优于依赖固定映射或预设融合流程的方法。CHNet采用粗-细两阶段特征处理，mPMCL通过层次化跨模态交互增

强特征对齐，MSAF引入掩码自注意力与多视图序列嵌入，以上方法在复杂区域中均缺乏充分的动态适配能力，难以根据空间异质性实时调整模态贡献。

(2)序贯决策机制与模态保真约束的协同作用进一步验证了动态融合和模态信息保护的重要性。




图 3 分类图(Houston2013)




图 4 分类图(MUUFL)




图 5 分类图(Trento)

表 1 Houston2013数据集的分类精度

类别(%)	CHNet	DSymFuser	mPMCL	MEDFN	S3F2Net	MSAF	DLCN
Healthy grass	100	88.98	100	84.25	98.39	98.29	97.15
Stressed grass	86.00	98.68	98.21	98.33	93.89	86.47	97.65
Synthetic grass	100	99.60	100	99.86	100	100	100
Trees	98.30	99.43	94.13	99.52	99.91	97.82	97.73
Soil	100	100	100	100	99.91	99.81	100
Water	100	100	100	92.62	100	99.30	100
Residential	98.13	99.81	98.69	92.82	99.91	98.41	99.72
Commercial	96.39	90.60	94.59	84.81	96.87	98.96	88.32
Road	99.81	87.82	89.24	68.69	43.34	94.33	98.68
Highway	90.44	94.21	100	84.51	100	97.97	100
Railway	96.58	97.15	92.13	91.58	100	98.96	99.43
Parking lot 1	100	96.06	98.27	81.02	99.52	97.31	97.60
Parking lot 2	100	92.98	95.08	95.95	100	99.65	96.14
Tennis court	100	98.79	100	99.77	100	100	100
Running track	100	100	100	100	100	99.36	99.79
OA	97.03	95.72	96.88	90.23	94.07	97.21	97.85
AA	97.71	96.28	97.36	91.58	95.44	97.78	98.15
Kappa	96.78	95.35	96.61	89.44	93.56	96.97	97.67

相比DSymFuser、MEDFN和S3F2Net, DLCN通过逐时间步决策优化与破坏性动作修正, 在充分利用多模态互补信息的同时保留模态特有特征, 因而在类别边界和异质区域中表现更优。此外, S3F2Net通过CNN与GCN结合捕捉局部与全局特征, 但其训练过程未显式考虑样本重要性差异, 难以在复杂地形中强化关键区域的学习, 这也验证了本文设计的关键样本导向采样模块的合理性。

(3) “决策-学习-修正” 闭环优化机制显著提升了模型对复杂场景的适应能力。价值引导策略优化实现融合策略动态演化, 关键样本导向采样强化复

杂样本学习, 模态保真约束保障模态信息完整性, 三者协同构成多维优化框架, 使DLCN在三个数据集上取得更稳定、更优的分类性能。

3.4 消融实验

为验证文中各组成部分的有效性, 设计了渐进式消融实验, 如表4所示。通过逐步添加价值引导策略优化机制(Optimization Mechanism for Value Guidance Strategy, OMVGS)、关键样本导向采样模块(Key Sample Oriented Sampling Module, KSOSM)和模态保真约束机制(Modal Fidelity Constraint Mechanism, MFCM)三个组件, 系统分

表 2 Trento数据集的分类精度

类别(%)	CHNet	DSymFuser	mPMCL	MEDFN	S3F2Net	MSAF	DLCN
Apple trees	99.46	96.72	94.55	96.12	100	99.90	99.28
Buildings	95.93	99.24	99.78	98.41	99.68	99.46	98.70
Ground	95.19	97.86	99.73	92.86	87.97	98.13	97.06
Woods	99.98	100	100	100	100	100	100
Vineyard	100	100	100	99.86	98.35	99.72	100
Roads	97.05	97.44	97.71	98.36	94.00	95.28	98.46
OA	99.17	99.20	99.01	99.01	98.62	99.32	99.58
AA	97.94	98.55	98.63	97.60	96.67	98.75	98.92
Kappa	98.89	98.93	98.68	98.67	98.15	99.09	99.44

表 3 MUUFL数据集的分类精度

类别(%)	CHNet	DSymFuser	mPMCL	MEDFN	S3F2Net	MSAF	DLCN
Trees	91.70	93.99	92.20	79.11	91.71	92.87	96.62
Mostly grass	86.41	88.13	87.79	92.57	87.62	86.60	89.25
Mixed ground surface	84.85	87.12	81.61	53.30	83.02	79.93	90.54
Dirt and sand	96.36	96.84	97.37	96.12	95.40	96.90	95.05
Road	89.20	91.19	86.40	82.33	90.21	89.00	93.24
Water	100	99.68	100	99.68	99.37	99.68	99.68
Building shadow	93.13	96.74	93.33	96.45	95.54	93.52	97.36
Building	95.34	95.42	97.72	86.81	90.03	95.75	96.29
Sidewalk	84.21	90.36	85.10	65.91	77.48	84.78	79.51
Yellow curb	100	96.97	100	81.82	96.97	93.94	90.91
Cloth panels	99.16	99.16	100	100	100	99.16	99.16
OA	90.61	92.62	90.51	79.25	89.88	90.57	94.38
AA	92.76	94.15	92.87	84.92	91.58	92.01	93.42
Kappa	87.68	90.27	87.55	73.61	86.74	87.60	92.52

表 4 消融模型

组件	Baseline-A	Baseline-B	Baseline-C	Baseline-D	DLCN
OMVGS	×	×	√	√	√
KSOSM	×	×	×	√	√
MFCM	×	×	×	×	√

析各组件对模型整体性能的独立贡献及协同作用，实验结果如表5所示。下面部分将对消融实验进行介绍：

Baseline-A：该模型采用多头自注意力机制完成高光谱与LiDAR特征融合。首先分别提取两种模态特征，然后通过多头注意力模块建模模态间与模态内的相关性，并利用加权聚合后的融合特征完成最终分类任务。

Baseline-B：在Baseline-A的基础上，以特征拼接融合方法替代多头自注意力机制融合方法。将高光谱与LiDAR特征在通道维度进行拼接，随后通过 1×1 卷积和全连接层完成特征压缩与分类。

Baseline-C：在Baseline-B的基础上，以OMVGS替代特征拼接融合方法，将多模态特征融合建模为序贯决策过程。通过Actor-Critic框架动态生成融合动作，并利用长期回报信号持续优化融合策略，实现上下文依赖的自适应特征融合，最终完成分类任务。

Baseline-D：在Baseline-C的基础上，进一步加入KSOSM。根据样本的决策困难度动态分配采样优先级，提高复杂区域和难分类样本在训练过程中的参与度，从而增强模型对关键样本的学习能力，进而完成分类任务。

DLCN：在Baseline-D的基础上，进一步加入MFCM。通过多维约束对融合动作进行评估与修正，在保持模态互补性的同时增强融合特征质量，进而完成分类任务。

实验结果具体分析如下：

(1)Baseline-C组件分析：与Baseline-A和Baseline-B相比，引入OMVGS后，模型在三个数据集上均取得稳定提升，说明序贯决策机制能够通过Actor-Critic网络动态调整融合权重，缓解静态融合方法在空间异质场景下适应性不足的问题。尤其在MUUFL复杂建筑阴影和混合地物较多的场景中，OMVGS对局部上下文变化的适应能力更为明显。

(2)Baseline-D组件分析：在Baseline-C基础上加入KSOSM后，模型性能进一步提升。KSOSM利用模态保真损失量化样本决策困难度，并提高类别边界、跨模态异质区域等关键样本的采样优先级，从而增强模型对复杂区域的判别能力。


(3)DLCN组件分析：在Baseline-D基础上加入MFCM后，模型获得进一步提升。MFCM通过光谱保真、特征一致性、结构保持和分辨率匹配等约束，对融合动作进行实时评估与修正，减少破坏性融合动作对HSI光谱特征和LiDAR结构特征的影响，从而保证融合策略的稳定演化。

(4)组件协同作用：OMVGS负责动态生成融合策略，KSOSM强化关键样本学习，MFCM约束并修正不合理融合动作，三者共同构成“决策-学习-修正”的闭环优化过程，使DLCN在复杂异质遥感场景中取得更稳定的分类性能。


此外，为验证DLCN的逐步优化能力，本文在Houston2013数据集上分析了模型随时间步变化的性能演化过程(如图6所示)。图6(a)中部分类别精度存在阶段性波动，图6(b)中光谱角呈现先增大后减小的趋势，说明模型在序贯决策过程中经历了探索

表 5 不同组件对OA的影响(%)

数据集	Baseline-A	Baseline-B	Baseline-C	Baseline-D	DLCN
Houston2013	95.71	94.61	96.15	97.38	97.85
Trento	96.46	97.28	98.27	99.07	99.58
MUUFL	91.09	90.21	92.54	93.86	94.38



(a) 一段时间步长各类别精度变化



(b) 一段时间步长上的光谱角度

图 6 DLCN在一段时间步长上

到利用的优化过程。相比固定权重融合方法, DLCN能够通过逐步调整融合策略避免陷入局部最优, 并最终收敛到更优的融合结果。

3.5 性能开销结果和分析

为评估各对比方法在实际工程应用中的计算效率与模型复杂度, 重点从浮点运算次数(FLOPs)、参数量(params)以及推理时间(Time)三个维度进行量化比较。我们在Houston 2013、Trento和MUUFL三个数据集上进行了实验, 结果如表6所示。从结果可以看出, DLCN在三个数据集上的推理时间均排名第一, 展现出较高的运行效率。同

时, 在FLOPs和参数量方面也保持了较优水平, 综合性能位居前列。由于引入了Actor-Critic决策网络和模态保真约束机制, DLCN的参数量和FLOPs有所增加。这部分额外开销主要用于实现面向局部上下文的动态融合决策以及对破坏性动作的实时修正, 使模型能够根据输入特征自适应地调整融合策略, 并有效保留模态特有信息。实验结果表明, 在计算开销可接受的前提下, DLCN不仅取得了最优的分类性能, 而且在推理效率方面也表现出明显优势, 说明所引入的额外计算代价能够有效转化为性能增益, 验证了该设计的有效性与合理性。

表 6 不同方法对每个数据集的计算代价

数据集	计算代价	CHNet	DSymFuser	mPMCL	MEDFN	S3F2Net	MSAF	DLCN
Houston 2013	Time(s)	3.07	6.42	15.36	2.34	1.99	1.61	1.32
	FLOPs(M)	334.28	75.43	7.59	165.76	57.50	3.92	161.42
	params(M)	23.78	0.85	0.17	1.45	0.28	0.05	0.79
Trento	Time(s)	7.83	5.35	25.96	2.14	0.93	7.167	0.86
	FLOPs(M)	334.18	41.36	27.69	164.98	10.89	3.76	160.25
	params(M)	23.73	0.47	0.18	1.45	0.27	0.05	0.79
MUUFL	Time(s)	14.31	9.40	34.36	3.56	2.56	14.75	2.23
	FLOPs(M)	334.23	41.85	7.57	164.54	8.68	3.77	160.40
	params(M)	23.75	0.48	0.17	1.45	0.28	0.05	0.79

4 结束语

本文针对传统静态融合方法难以适应遥感场景空间异质性的问题, 提出一种面向HSI与LiDAR融合分类的决策-学习-修正网络, 将多模态融合过程建模为序列决策任务。该方法通过价值引导策略优化动态调整融合权重, 利用关键样本导向采样增强复杂类别边界的判别能力, 并引入模态保真约束实时修正破坏性动作, 以保护模态特有信息。三者构成闭环优化机制, 协同提升异质场景下的融合质量与分类性能。实验结果表明, 该方法在三个公开数据集上均取得最优表现。未来工作将进一步研究精细判别特征学习与鲁棒动态融合策略, 以提升模型在复杂场景和不同数据条件下的泛化能力。

参 考 文 献

- [1] ZHAO Xudong, ZHANG Mengmeng, TAO Ran, *et al.* Fractional Fourier image transformer for multimodal remote sensing data classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(2): 2314–2326. doi: [10.1109/TNNLS.2022.3189994](#).
- [2] WU Xin, HONG Danfeng, and CHANUSSOT J. Convolutional neural networks for multimodal remote sensing data classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5517010. doi: [10.1109/TGRS.2021.3124913](#).
- [3] VIVONE G, DENG Liangjian, DENG Shangqi, *et al.* Deep learning in remote sensing image fusion: Methods, protocols, data, and future perspectives[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2025, 13(1): 269–310. doi: [10.1109/MGRS.2024.3495516](#).
- [4] LUO Fulin, HUA Yiyan, FU Chuan, *et al.* MMD-MLP: LiDAR-guided hyperspectral data classification using local-global directional-MLP with multiresolution multiscale representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5508414. doi: [10.1109/TGRS.2025.3550370](#).
- [5] DUAN Puhong, LUO Yichen, KANG Xudong, *et al.* LaMamba: Linear attention mamba for hyperspectral image denoising[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5527113. doi: [10.1109/TGRS.2025.3613739](#).
- [6] FU Chuan, DU Bo, and ZHANG Liangpei. ReSC-net: Hyperspectral image classification based on attention-enhanced residual module and spatial-channel attention[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5518615. doi: [10.1109/TGRS.2024.3402364](#).
- [7] YU Chunyan, WANG Hande, SONG Meiping, *et al.*

- Interactive graph-based distillation integrated meta-learning network for hyperspectral image incremental classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2026, 64: 5500316. doi: [10.1109/TGRS.2025.3647656](https://doi.org/10.1109/TGRS.2025.3647656).
- [8] DONG Wenqian, YANG Teng, QU Jiahui, *et al.* Joint contextual representation model-informed interpretable network with dictionary aligning for hyperspectral and LiDAR classification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 33(11): 6804–6818. doi: [10.1109/TCSVT.2023.3268757](https://doi.org/10.1109/TCSVT.2023.3268757).
- [9] YANG J X, ZHOU Jun, WANG Jing, *et al.* LiDAR-guided cross-attention fusion for hyperspectral band selection and image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5515815. doi: [10.1109/TGRS.2024.3389651](https://doi.org/10.1109/TGRS.2024.3389651).
- [10] YANG Bin, WANG Xuan, XING Ying, *et al.* Modality fusion vision transformer for hyperspectral and LiDAR data collaborative classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 17052–17065. doi: [10.1109/JSTARS.2024.3415729](https://doi.org/10.1109/JSTARS.2024.3415729).
- [11] HE Ziping, ZHU Qianglin, WANG Wei, *et al.* Multilevel fusion network based on mix hybrid attention for hyperspectral and LiDAR image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2026, 19: 470–483. doi: [10.1109/JSTARS.2025.3628896](https://doi.org/10.1109/JSTARS.2025.3628896).
- [12] WANG Minhui, SUN Yaxiu, XIANG Jianhong, *et al.* Joint classification of hyperspectral and LiDAR data based on adaptive gating mechanism and learnable transformer[J]. *Remote Sensing*, 2024, 16(6): 1080. doi: [10.3390/rs16061080](https://doi.org/10.3390/rs16061080).
- [13] WANG Haoyu, CHENG Yuhu, LIU Xiaomin, *et al.* Reinforcement learning based Markov edge decoupled fusion network for fusion classification of hyperspectral and LiDAR[J]. *IEEE Transactions on Multimedia*, 2024, 26: 7174–7187. doi: [10.1109/TMM.2024.3360717](https://doi.org/10.1109/TMM.2024.3360717).
- [14] SCHULMAN J, WOLSKI F, DHARIWAL P, *et al.* Proximal policy optimization algorithms[J]. *arXiv preprint arXiv: 1707.06347*, 2017. doi: [10.48550/arXiv.1707.06347](https://doi.org/10.48550/arXiv.1707.06347).
- [15] DEBES C, MERENTITIS A, HEREMANS R, *et al.* Hyperspectral and LiDAR data fusion: Outcome of the 2013 GRSS data fusion contest[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2405–2418. doi: [10.1109/JSTARS.2014.2305441](https://doi.org/10.1109/JSTARS.2014.2305441).
- [16] RASTI B, GHAMISI P, and GLOAGUEN R. Hyperspectral and LiDAR fusion using extinction profiles and total variation component analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3997–4007. doi: [10.1109/TGRS.2017.2686450](https://doi.org/10.1109/TGRS.2017.2686450).
- [17] ZHANG Mengmeng, LI Wei, TAO Ran, *et al.* Information fusion for classification of hyperspectral and LiDAR data using IP-CNN[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5506812. doi: [10.1109/TGRS.2021.3093334](https://doi.org/10.1109/TGRS.2021.3093334).
- [18] NI Kang, XIE Yunan, ZHAO Guofeng, *et al.* Coarse-to-fine high-order network for hyperspectral and LiDAR classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5509716. doi: [10.1109/TGRS.2025.3554802](https://doi.org/10.1109/TGRS.2025.3554802).
- [19] CHANG Honghao, BI Haixia, LI Fan, *et al.* Deep symmetric fusion transformer for multimodal remote sensing data classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5644115. doi: [10.1109/TGRS.2024.3476975](https://doi.org/10.1109/TGRS.2024.3476975).
- [20] LIU Hui, HUANG Chenjia, XIE Tao, *et al.* Positive matching benefits fusion: A novel contrastive learning framework for hyperspectral and LiDAR data classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2026, 64: 5502218. doi: [10.1109/TGRS.2026.3654168](https://doi.org/10.1109/TGRS.2026.3654168).
- [21] WANG Xianghai, SONG Liyang, FENG Yining, *et al.* S3F2Net: Spatial-spectral-structural feature fusion network for hyperspectral image and LiDAR data classification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(5): 4801–4815. doi: [10.1109/TCSVT.2025.3525734](https://doi.org/10.1109/TCSVT.2025.3525734).
- [22] SHI Lulu, LI Chunchao, ZENG Zhengchao, *et al.* Masked self-attention fusion network for joint classification of hyperspectral and LiDAR data[J]. *IEEE Transactions on Image Processing*, 2026, 35: 346–360. doi: [10.1109/TIP.2025.3648926](https://doi.org/10.1109/TIP.2025.3648926).
- 王浩宇：男，副教授，研究方向为高光谱图像分类、多模态融合、机器学习。
- 刘诺菲：女，在读硕士生，研究方向为强化学习、多模态融合、深度学习。
- 程玉虎：男，教授，研究方向为强化学习、图像处理、深度学习。
- 刘晓敏：女，副教授，研究方向为强化学习、多模态融合、图像处理。
- 王雪松：女，教授，研究方向为强化学习、图像处理、深度学习。

Decision Learning Correction Network for HSI and LiDAR Fusion Classification

WANG Haoyu^① LIU Nuofei^① CHENG Yuhu^①
 LIU Xiaomin^① WANG Xuesong^①

^①(School of Information and Control Engineering, China University of Mining and Technology,
 Xuzhou 221116, China)

Abstract:

Objective Hyperspectral images(HSI) and LiDAR data provide complementary information for land-cover classification. HSI contains rich spectral responses for material discrimination, while LiDAR supplies elevation and structural information for spatial perception. However, most existing fusion methods treat multimodal fusion as a static aggregation process, assuming that a fixed fusion rule is suitable for all pixels and regions. This assumption is difficult to satisfy in complex remote sensing scenes, where class boundaries and cross-modal heterogeneous regions show higher information density but occupy only a small proportion of samples (Fig.1). To address this problem, this paper proposes a Decision Learning Correction Network (DLCN), which transforms static HSI-LiDAR fusion into a context-dependent sequential decision-making process.

Methods The proposed DLCN consists of feature extraction, fusion decision learning, and final classification. First, HSI and LiDAR are processed by two parallel branches to extract spectral-spatial features and elevation-structural features, respectively. Then, the extracted features are concatenated as the current fusion state and input into an Actor-Critic framework. The Actor network generates fusion actions to dynamically adjust modal contributions, while the Critic network evaluates the long-term value of each action for final classification. To improve the learning of difficult samples, a key-sample-oriented sampling module assigns higher sampling probabilities to samples with larger modal fidelity losses. Meanwhile, a modal fidelity constraint mechanism evaluates spectral fidelity, feature consistency, structural preservation, and resolution matching, and corrects destructive actions during fusion. Through this closed-loop structure, DLCN realizes dynamic fusion action generation, evaluation, and correction (Fig. 2).

Results and Discussions Experiments are conducted on Houston2013, Trento, and MUUFL datasets. DLCN achieves the best OA values of 97.85%, 99.58%, and 94.38% on the three datasets, respectively, outperforming CHNet, DSymFuser, mPMCL, MEDFN, S3F2Net, and MSAF. The classification maps show that DLCN effectively reduces misclassification in class-boundary, mixed land-cover, and structurally complex regions, producing results closer to the ground-truth maps on the three datasets (Fig. 3–Fig. 5). Ablation results demonstrate that the value-guided policy optimization mechanism, key-sample-oriented sampling module, and modal fidelity constraint mechanism all contribute to performance improvement. Compared with the baseline model, the complete DLCN obtains consistent OA gains on Houston2013, Trento, and MUUFL, verifying the effectiveness of the proposed decision-learning-correction framework. The temporal analysis shows that DLCN gradually improves class accuracy while maintaining stable spectral-angle variation during sequential decision steps (Fig. 6). In addition, DLCN achieves inference times of 1.32 s, 0.86 s, and 2.23 s on the three datasets, respectively, ranking first among the compared methods. This indicates that the introduced Actor-Critic decision mechanism and modal fidelity constraints can be effectively converted into classification gains without causing excessive computational burden.

Conclusions This paper proposes DLCN for HSI and LiDAR fusion classification. Different from static fusion methods, DLCN models multimodal fusion as a sequential decision-making process and dynamically adjusts fusion strategies according to local context. The closed-loop design enables the model to generate, evaluate, and correct fusion actions. Experimental results show that DLCN achieves more accurate classification maps in heterogeneous scenes, and the temporal analysis further confirms the stability of the sequential decision process. Future work will focus on more fine-grained feature representation and more robust policy optimization to improve generalization in complex remote sensing scenes.

Key words: Hyperspectral images; LiDAR; Multimodal fusion; Sequential decision optimization; Classification