



# 加强局部自相似性描述符在多模态遥感图像匹配中的应用

冷成财,洪雅萌

(西北大学 数学学院,陕西 西安 710127)

**摘要** 多模态遥感图像之间存在复杂差异与多样内容,导致匹配任务难以精确完成。尽管传统的局部自相似性(local self-similarity, LSS)描述符能够捕捉图像中的显著结构与轮廓,但由于差异复杂,往往难以实现精确的特征对应。为此,在描述符构建过程中引入基于图模型的特征筛选方法,节点集和边集分别表示局部单元内不同角度的LSS特征及其相似性关系。通过记录相关性排序索引并生成排序频率直方图,对LSS进行重构,仅保留最相关的特征,从而降低对强度信息的依赖。实验在3个公开数据集(含4类跨模态场景,250张测试图像)中验证有效性。定量分析表明,结合4类典型特征检测器后,ELSS(enhanced LSS)最高可获得276.92的NCM值和2.08的RMSE值,优于其他6种对比方法,证明了ELSS能有效缓解辐射和几何差异对多模态图像任务的限制,验证了其在多模态图像精准匹配任务下的适用性。

**关键词** 多模态遥感图像匹配;局部自相似性;特征选择

中图分类号:TP751.1 DOI:10.16152/j.cnki.xdxbr.2025-06-005

## Application of an enhanced local self-similarity descriptor for multimodal remote sensing images matching

LENG Chengcai, HONG Yameng

(School of Mathematics, Northwest University, Xi'an 710127, China)

**Abstract** Multi-modal remote sensing images exhibit complex discrepancies and diverse contents, posing significant challenges for precise matching tasks. While traditional local self-similarity (LSS) descriptors can capture salient structures and contours, their ability to establish accurate feature correspondences remains limited due to these intricate variations. To address this, we propose an enhanced LSS (ELSS) descriptor incorporating graph-based feature selection during descriptor construction. The method models LSS features at different angles within local patches as graph nodes, with edges representing their similarity relationships. By recording correlation ranking indices and generating ranking frequency histograms, we reconstruct LSS to retain only the most relevant features, thereby reducing its dependency on intensity information. Experiments on three public datasets (encompassing four cross-modal scenarios with 250 test images) validate the effectiveness of our enhanced LSS. When combined with four representative feature detectors, ELSS achieves state-of-the-

收稿日期:2025-09-24

基金项目:国家自然科学基金天元基金(12326612);陕西省自然科学基金(2025JC-YBMS-772);中国国家留学基金管理委员会国家公派奖学金项目(202406970047)。

第一作者:冷成财,男,教授,博士生导师,从事数据处理与统计分析、图像处理等研究,ccleng@nwu.edu.cn。

art results; 276.92 for number correct matches (NCM) and 2.08 for root mean square error (RMSE), outperforming six competing methods. These results validate ELSS's effectiveness in mitigating radiometric and geometric variations for robust multimodal image matching.

**Keywords** multimodal remote sensing image matching; local self-similarity; feature selection

图像匹配在航空与环境监测、自主导航、机器人定位和测绘等领域具有重要应用价值<sup>[1]</sup>,并在图像处理与计算机视觉研究中受到广泛关注。随着遥感技术的进步,多模态数据在信息维度和语义丰富度方面持续扩展,为图像匹配研究带来新的机遇与挑战<sup>[2]</sup>。特别是近年来,多模态遥感图像(multimodal remote sensing image, MRSI)匹配已发展成为计算机视觉领域的重要研究方向,其核心价值在于通过多源信息融合获取更全面、更可靠的环境感知能力。以可见光与红外图像为例:可见光成像具有极强的视觉可解释性,但易受大气条件影响;而红外成像虽抗干扰能力强,却存在噪声大、对比度低的缺陷<sup>[3,4]</sup>。通过融合 2 种成像模态的互补优势,可显著提升相关衍生应用对信息的利用水平<sup>[5-6]</sup>。

MRSI 匹配方法主要分为传统方法和深度学习方法两大类。深度学习方法基于数据驱动范式,通过深度神经网络自动提取多层次特征表示,从输入数据中抽象出潜在分布结构<sup>[7]</sup>,在充足的数据支撑下,处理高维非结构化数据时表现出卓越的泛化能力<sup>[8]</sup>。然而,这类方法通常需要大量计算资源和训练数据,且模型可解释性较差。相比之下,传统方法通过手工设计(handcrafted)特征,具有计算效率高、无需训练数据等优势,在实时性要求较高的应用场景中更具竞争力。此外,传统方法的模块化设计便于针对特定任务进行调整优化,其处理流程也更具可解释性。

按照特征匹配框架,基于传统的方法可进一步分为基于区域(area-based)和基于特征(feature-based)的方法。前者亦称模板匹配(template matching),通常采用滑动窗口策略计算模板图像与参考图像的相似度,以确定最优匹配位置,常用的相似性度量包括平方差之和(sum of squared differences)、归一化互相关(normalized cross correlation)及互信息(mutual information)<sup>[9]</sup>。然而,该方法对几何畸变较为敏感,难以应对 MRSI 匹配任务中的旋转与尺度变化问题。后者通常包括关键点检测、关键点描述和特征向量匹配 3 个阶段,核心在于提取图像间显著特征点,并设计描述

符衡量其相似性<sup>[10]</sup>。然而,在 MRSI 匹配任务中,该类方法依赖于高度可重复性的同名点检测,易受非线性辐射畸变和强度差异影响,导致匹配精度下降。

针对以上问题,Xiang 等人在 SIFT(scale invariant feature transform)<sup>[11]</sup>框架下,通过多个图像块提取梯度方向直方图类描述符,以达到增强特征的目的<sup>[12]</sup>;Ye 等人提出捕捉图像间的形状相似性,使描述符建立与强度模式无关,提高了对非线性强度差异的鲁棒性<sup>[13]</sup>;Xiong 等人进一步构建基于秩的局部自相似性方法,以增强可见光-SAR 图像模板匹配的可区分性<sup>[14]</sup>。然而,这些方法往往针对 MRSI 特定场景进行优化,当数据源变化时,手工设计的特征需要重新调整,以维持匹配性能。

现有研究还尝试利用频域特征等技术开发多种变体方法,以处理 MRSI 匹配中的几何与辐射差异,从而提高匹配精度。Li 等人提出以相位一致性(phase congruency)替代图像强度来检测特征点,利用最大索引图建立特征描述<sup>[15]</sup>;Hong 等人结合局部形状相似性及最大索引图信息,进一步提升了传统方法在 MRSI 任务中的适用性<sup>[16]</sup>;Yao 等人提出基于共现滤波空间的鲁棒方法,可有效削弱或消除非线性辐射畸变差异<sup>[17]</sup>。

然而,传统方法在大规模、多样化数据下匹配性能往往难以保持稳定,尤其在旋转或尺度变化的场景中,现有算法普遍失效。主要因为其依赖于强度信息和手工特征提取,仅能获取浅层轮廓与结构特征,易受多模态数据差异影响。特别是 Li 等人构建的多模态图像数据集涵盖多种图像场景<sup>[18]</sup>,包含辐射、强度差异及几何变形等因素,进一步增加了匹配难度,对算法的稳健性与精准度提出了更高要求。

针对传统 MRSI 匹配方法的局限性,本文基于局部自相似性<sup>[19]</sup>(local self-similarity, LSS)构建密集特征描述符。LSS 具有实现简单的优势,但其强烈依赖图像强度信息,意味着结构特征提取能力越强,越容易受到几何和辐射差异的影响。本研究的目标是通过特征滤波挖掘内在相似性,

从而减少畸变和噪声等不利因素对匹配精度的影响,以弥补传统方法仅能提取浅层特征的不足,深度融合多级图像特征,提升基于 LSS 的传统方法在 MRSI 任务中的适用性。

基于以上分析,本文提出一种增强型 LSS 方案(enhanced LSS, ELSS),采用基于图的滤波器进行特征选择,并挖掘深层特征相似性以实现更精确的 MRSI 匹配。通过记录相关性得分并构建排序频率直方图,原始 LSS 特征得以重构,新描述符能更好地适应 MRSI 的差异性。为测试 ELSS 在不同算法中的适用性,使 4 种经典的特征检测器分别与所提描述符结合,构成 4 种算法用于实验。本文在包含 4 种数据模态,共 250 对图像的 3 个不同数据集上开展定性及 3 项定量评估实验,对所提出方法的有效性进行验证。

1 方法

1.1 局部自相似性特征

在图像匹配任务中,描述符的构建是影响匹配效率和精度的关键步骤之一,也可广义地称为图像对应关系(correspondence)的建立。在匹配过程中,通常 2 幅图像之间存在共同的底层视觉属性,如像素颜色、强度、边缘、梯度或其他滤波器

响应。这些潜在的局部强度模式往往以相似的几何布局在图像的特征位置反复出现。MRSI 间的复杂差异通常会导致匹配过程中误差累积,这一现象在特征检测与描述阶段尤为显著。然而,不同模态间的地形轮廓与目标形状却仍保持相似性,这为局部自相似性(LSS)描述符应对 MRSI 匹配挑战提供了可行性基础。本文算法的主要目标是有效地提取并利用这 2 幅图像之间共享的局部自相似模式。在下文表述中,“LSS 特征”与“LSS 描述符”将作为同义术语交替使用。图 1 展示了 LSS 描述符的生成过程,其中,箭头标示了 LSS 的对应组成要素。示例 1 和 2 通过中心像素(关键点)将不同间隔与角度下的 LSS 特征可视化,清晰表明参考图像与待匹配图像中的特征均呈现结构相似性。LSS 描述符的数学定义如下:

$$S_q(x,y) = \exp\left[-\frac{SSD_q(x,y)}{\max(V_{noise},V_{auto(q)})}\right] \quad (1)$$

式中:SSD<sub>q</sub>(x,y) 通过平方差和(sum of squared differences) 计算,表示以 q 像素为中心的相邻图像块之间的距离曲面;V<sub>noise</sub> 和 V<sub>auto(q)</sub> 为常数,分别对应可接受的光度变化量以及 q 点极小邻域内所有图像块差异的最大方差。最终获取的相关性曲面 S<sub>q</sub>(x,y) 经过转换后,将被划分至对数极坐标网格。




图 1 LSS 特征生成示例  
Fig.1 An example of LSS feature generation

LSS 描述符可用于初步捕获图像中的浅层特征,并通过极小的样本特征尺寸获取关键结构信

息。例如,设置 3 个径向间隔和 7 类角度划分可生成 21 个不同的特征区间(bin),每个区间包含最大相关值。需注意的是,若径向间隔或角度设置过大,LSS 特征会出现扩散现象并导致精度损失,即单个区间将包含多个结构特征,且无关信息会相互干扰。此外可见,该特征计算过程高度依赖图像强度,这意味着从 MRSI 直接获取的 LSS 特征无法直接用于匹配,否则 MRSI 间显著的强度与辐射差异将降低匹配精度。如图 1 展示的待匹配 SAR 图像,其中包含的斑点噪声对图像对应关系的准确建立产生不小的影响,最终导致描述符间存在不完全相似的差异性。为了解决这一问题,并提高 LSS 描述符在多模态图像匹配任务中的结构特征捕捉能力,需要对初步提取的 LSS 特征进一步处理和优化。

## 1.2 基于排序相关的 LSS 特征重建

对于  $n$  个关键点,原始 LSS 方法仅产生  $n \times bins$  个特征向量,显然难以满足精确匹配的需求。如图 1 红色框所示,本文提出在 LSS 计算区域外设置一个扩展单元(local cell)。在该单元中,以关键点为中心逐点生成密集的 LSS 特征,增强 2 幅图像局部结构相似性。这种方法无需增加径向间隔或角度设置即可有效提升特征的维度和密度。但逐点计算方式在重叠区域可能会引入冗余信息,尤其在多模态图像匹配任务中,由于图像间差异引发的匹配误差可能进一步放大,因此还需引入特征过滤机制以减轻其影响。

特征选择的过滤方法利用数据的内在属性(如相关性、方差或其他统计量)来评估特征价值。该方法能够筛选出相关且非冗余的特征,实现降维并提升数据可解释性。Roffo 等人提出的无监督方法<sup>[20]</sup>为此提供了理论基础,研究表明基于图的无监督特征过滤(graph-based feature filtering)可应用于 LSS 特征的重构。

针对局部单元内每个像素在划分角度  $a_n$  下的 LSS 特征集合  $F = \{f_1, f_2, \dots, f_{a_n}\}$ ,本文构建了一个加权无向全连接图  $G = (V, E)$ 。其中,节点集  $V = \{v_1, v_2, \dots, v_{a_n}\}$  表示各角度特征,边集  $E$  则建模节点间的关联关系。需特别说明的是,特征  $f$  包含扩展单元内所有像素在单一角度下的全部 LSS 特征。邻接矩阵  $A$  的元素  $A(i, j)$  用于建模特征对  $f_i$  和  $f_j$ (即节点对  $v_i$  和  $v_j$ ) 被同时选中的置信度( $1 \leq i, j \leq a_n$ ):

$$A(i, j) = \phi(v_i, v_j) \quad (2)$$

$$\phi(v_i, v_j) = \alpha E_{ij} + (1 - \alpha) \overline{\text{corr}_{ij}} \quad (3)$$

式中: $\phi$  为关联权重函数,其值由特征的方差和相关性共同决定; $\alpha \in [0, 1]$  为加载系数。2 个分布  $E_{ij}$  的最大归一化标准差与相关系数  $\overline{\text{corr}_{ij}}$  可分别表示为:

$$E_{ij} = \max(\sigma_i, \sigma_j) \quad (4)$$

$$\overline{\text{corr}_{ij}} = 1 - |\text{Spearman}(f_i, f_j)|$$

式中: $\sigma_i$  与  $\sigma_j$  表示样本集  $\{f_i\}$  和  $\{f_j\}$  的标准差,  $\text{Spearman}(\cdot)$  为斯皮尔曼排序相关系数。

在给定路径长度  $l$  下,第  $i$  个特征的单特征评分  $c_l(i)$  可通过下式评估:

$$c_l(i) = \sum_{j \in V} A^l(i, j) \quad (5)$$

$c_l(i)$  值越大表征特征质量越优,特征选择优先级可按照  $c_l$  的降序排列。当待选特征集规模较大时,Roffo 等人提出可通过计算高效的方式解决排序问题<sup>[20]</sup>,其简化表达式为:

$$\begin{cases} \check{C} = (I - rA)^{-1} - I \\ \check{c} = [\check{C}e] \end{cases} \quad (6)$$

式中:矩阵  $\check{C}$  为编码特征集合的局部评分; $r$  为实值正则化因子; $e$  为一维向量; $[\cdot]$  表示向量元素的提取操作。本匹配算法采用按降序排列的  $\check{c}$  向量进行特征选择。

将降序排列记录为  $R(\check{c})$  后,选取前  $k$  位的索引构成秩立方体(rank cube)。如图 2 所示,以关键点为中心的描述符区块(其尺寸通常远大于扩展单元)可获取充分的秩频率信息。具体实现分为 3 个阶段:首先,根据关键点主导方向(通过梯度方向计算确定)对区块进行定向,随后在区块内以像素为单位遍历扩展单元窗口,通过基于图的特征滤波生成系列秩索引;其次,将不同层级的索引展开至独立的描述符区块,即将每个区块等分为  $m \times m$  子区域后展开为  $m^2 \times k$  的矩阵;最后,在各独立描述符区块中计算秩频率直方图并拼接形成关键点的 ELSS 描述符。ELSS 的秩索引编码器降低了传统 LSS 特征对强度的依赖性,其秩频率直方图则显著提升了描述符的判别能力。采用  $k$  层立方体结构可确保基于图的滤波不受噪声与畸变影响,因为单一顶层  $R(\check{c})$  易定位非显著 LSS 特征(2.3 节给出了相关实验)。




图 2 ELSS 构建细节图  
Fig. 2 Detailed construction of ELSS descriptor

1.3 ELSS 实现框架

本文将所提出的 ELSS 描述符应用于经典图像匹配框架中,该框架主要包含 3 个核心步骤:特征检测、特征描述与特征匹配。为验证 ELSS 的适应性与性能,选用 4 类典型的关键点检测算子嵌入框架中,包括 FAST<sup>[21]</sup> (features from accelerated segment test)、ORB<sup>[22]</sup> (oriented FAST and rotated BRIEF)、Harris<sup>[23]</sup> (Harris-Stephens) 以及 BRISK<sup>[24]</sup> (binary robust invariant scalable key-points)。对于输入图像,首先利用相位信息构建最大矩图(maximum moment map),并在其上执行关键点检测。该图能有效提供边缘结构信息,具有更强的抗辐射扰动能力<sup>[15]</sup>,进而降低检测误差。上述各类检测器的关键点数量统一设定为不超过 5 000 个。

最终,在特征匹配阶段采用强力匹配策略(brute force matching, BFM),即不进行最近邻距离比率(nearest neighbor distance ratio, NNDR)测试,直接对特征描述符进行匹配筛选。该方法能够直观展示所提出算法在匹配任务中的性能,尤其可用于评估描述符的构建是否具备有效性和精确性。

2 实验

2.1 数据集

本文选取 3 个多模态图像公开数据集作为主要数据来源,包含 4 种不同类型,共计 250 个图像对,表 1 列出了数据集的基本信息。

表 1 数据集信息  
Tab. 1 The main information of datasets

| 数据集   | 场景类型             | 数量 | 图像大小/像素                   | 分辨率       | 旋转变 | 尺度变化 | 辐射差异 | 下载地址                                                                                                          |
|-------|------------------|----|---------------------------|-----------|-----|------|------|---------------------------------------------------------------------------------------------------------------|
| 数据集 1 | Optical-Optical  | 50 | 256 × 256 ~ 1 024 × 1 024 | 4 ~ 16 cm | ✓   | ✓    | ✓    | <a href="https://github.com/LJY-RS/SRIF">https://github.com/LJY-RS/SRIF</a>                                   |
|       | Optical-Infrared | 50 | 256 × 256                 | 30 m      | ✓   |      | ✓    |                                                                                                               |
|       | Optical-Map      | 50 | 400 × 400                 | 1 m       |     |      | ✓    |                                                                                                               |
| 数据集 2 | Optical-SAR      | 50 | 512 × 512                 | —         | —   | —    | ✓    | <a href="https://pan.baidu.com/s/14bqaJhMSZEy7EXcXVAc77w">https://pan.baidu.com/s/14bqaJhMSZEy7EXcXVAc77w</a> |
| 数据集 3 | Optical-SAR      | 50 | 256 × 256                 | —         | —   | —    | ✓    | <a href="https://github.com/yaoxu008/QXS-SAROPT">https://github.com/yaoxu008/QXS-SAROPT</a>                   |

1)数据集 1。该数据集由 Li 等人<sup>[18]</sup>创建,是当前最新的多模态图像匹配数据集。数据集包含 6 种数据类型:可见光-可见光(optical-optical)、可见光-红外(optical-infrared)、可见光-SAR(optical-SAR)、可见光-深度(optical-depth)、可见光-地图(optical-map)和夜间(nighttime)。每种数据类型均包含 200 对多模态图像。

在这些图像中,所有图像对均存在非线性辐射差异。除 optical-map 外,其余图像类型均在原始图像的基础上随机加入角度范围为 $[0^\circ, 90^\circ)$ 的旋转变化。此外, optical-optical 和 optical-SAR 图像对还额外随机加入了尺度范围为 $[0.5, 2)$ 的尺度变化。此多样化的测试集有助于全面评估所提出方法的鲁棒性和匹配精度,也进一步增加匹配任务的挑战性。

本文从 optical-optical、optical-infrared 和 optical-map 3 种数据类型中各随机抽取 50 对图像,共计 150 对,作为实验测试样本。

2)数据集 2。OS-DATASET<sup>[25]</sup>包含 2 673 个大小为 $256 \times 256$ 像素和 10 692 个大小为 $512 \times 512$ 像素的 optical-SAR 图像对。SAR 图像由中国高分三号卫星在 Spotlight 模式下的 C 波段传感器获取,对应的可见光图像则来自谷歌地球平台。该数据集涵盖了全球超过 15 个城市的区域图像,包括北京、武汉、雷恩、奥马哈和德瓦卡等。为提高图像质量,数据集对所有图像对进行了目视检查,去除了包含变换扭曲或明显土地覆盖变化的不满意区域。此外,还利用图像增强技术对 SAR 图像进行了灰度可视化处理,以提升其可辨识度。

本文从中随机选取 50 对大小为 $512 \times 512$ 像素的 optical-SAR 图像对,作为测试样本,以验证所提出方法的有效性和鲁棒性。

3)数据集 3。QXS-SAROPT<sup>[26]</sup>包含 20 000 对大小为 $256 \times 256$ 像素的 optical-SAR 图像块,覆盖圣地亚哥、上海和青岛三大港口城市。地理环境涉及内陆、海洋和山区等,内容不仅关注建筑物,还涵盖港口和各种土地类型。QXS-SAROPT 已成为 optical-SAR 数据融合和深度学习研究(如场景分类)中的重要基准数据集。与数据集 2 类似,SAR 图像由高分辨率 SAR 传感器采集,可见光图像来源于高质量遥感平台,图像均经过筛选和预处理,以减少因变换扭曲或土地覆盖变化引起的误差。

本文从该数据集中随机抽取 50 对图像作为

测试样本。

## 2.2 实验评价指标及设计

本文采用正确匹配数(number of correct matching, NCM)、均方根误差(root mean square error, RMSE)和成功率(success rate, SR)对实验结果进行定量评价。在特征匹配阶段,图像对应残差(residual error of correspondence)小于 3 个像素的匹配点被视为正确匹配。NCM 和 RMSE 是直观有效的指标,用于衡量算法和特征描述符在建立图像对应关系时的准确性。SR 则表示成功匹配在所有任务中的占比,评估算法在不同数据集和复杂图像差异处理中的适用性。如果 $NCM \leq 10$ ,则将图像对标记为不匹配,并将 RMSE 统一记录为 $20^{[27]}$ ,以简化统计分析。为确保结果可靠,实验数据经过逐一验证,并对每组数据运行算法 5 次,最终结果为 5 次实验的平均值。

实验内容主要包括 3 部分:参数选择、对比实验和消融实验。在对比实验中,本文将提出的算法与 sRIFD<sup>[28]</sup>、RDFM<sup>[29]</sup>、MSHMO<sup>[30]</sup>、CoF-SM<sup>[17]</sup>、MLSS<sup>[16]</sup>、RIFT<sup>[15]</sup>、OS-SIFT<sup>[11]</sup>和 SIFT<sup>[12]</sup>进行比较。所有方法均采用文献中建议的参数设置。在特征检测阶段,检测器统一设置为最大检测 5 000 个特征点;在特征匹配阶段,均使用 BFM 算法以确保对比实验的公平性。

## 2.3 参数选择

本文涉及的主要参数共 3 个,包括 LSS 的扩展单元大小(LC)、描述符区块大小(DP)和  $k$  层立方体结构。如文献[13-14]所建议,本实验采用 9 类角度划分和 2 个径向间隔的 LSS 特征配置。基于图的特征滤波中,系数  $\alpha$  通常以交叉验证的方法来估计其值:当  $\alpha$  值较大时,特征的标准差信息占主导地位;当  $\alpha$  值较小时,特征间的相关性信息占主导地位。当该方法应用于多模态图像匹配任务中,丰富的图像内容通常是未知的。因此,在无明确选择依据下, $\alpha = 0.5$  是合理的默认设置起点,可用于平衡 2 种信息。

实验中选择 NCM、RMSE 作为评价指标,并采用所有数据集类型的前 20 组图像(共 100 组)进行测试,快速确定 LC、DP 与  $k$  的最优参数。该实验设计旨在通过小部分数据快速评估参数设置对实验结果的影响,且由于涉及不同数据集,实验结果具备较高的可靠性。

表 2~4 展示了结合 FAST 检测器时,ELSS 方法在不同参数配置下的性能表现。表中加粗的

为最优 NCM 值。综合分析表 2~4 的数据可知,不同参数对 NCM 和 RMSE 的影响存在显著差异。固定  $k=3$ ,当 LC 和 DP 分别为  $5 \times 5$  和  $120 \times 120$  时,NCM 达到峰值(300.57),同时 RMSE 保持较低水平(1.988);固定  $LC=5 \times 5$ , $DP=120 \times 120$ ,当  $k=3$  时 NCM 最优, $k=4$  时 RMSE 最低(1.866)。与  $k$  值相比,LC 和 DP 对实验结果影响相对较低,算法性能在一定参数范围内呈现稳定趋势,而  $k$  需严格选定为 3 或 4,以避免匹配精

度浮动过大。在 RMSE 相对稳定的情况下,以 NCM 为优先评价标准。因此,本文 ELSS 方法最终确定  $LC=5 \times 5$ 、 $DP=120 \times 120$  和  $k=3$ 。特别地,在表 4 的不同  $k$  值的参数实验中,可以得出对应结论:采用 3 层  $k$  值生成的描述符确保了基于图的滤波不受噪声与畸变影响,在应用中取得更精准的匹配效果,而取单一顶层  $R(\check{c})$  构建的描述符易定位非显著 LSS 特征,从而导致匹配性能下降。

表 2 不同 LC 的 NCM 和 RMSE 结果  
Tab. 2 The NCM and RMSE results for different LC

| 指标     | LC(固定参数:DP = 120 × 120, k = 3) |               |        |        |         |         |
|--------|--------------------------------|---------------|--------|--------|---------|---------|
|        | 3 × 3                          | 5 × 5         | 7 × 7  | 9 × 9  | 11 × 11 | 13 × 13 |
| NCM ↑  | 283.21                         | <b>300.57</b> | 290.70 | 269.03 | 251.45  | 235.83  |
| RMSE ↓ | 1.975                          | 1.988         | 1.989  | 1.998  | 2.000   | 2.009   |

表 3 不同 DP 的 NCM 和 RMSE 结果  
Tab. 3 The NCM and RMSE results for different DP

| 指标     | DP(固定参数:LC = 5 × 5, k = 3) |         |         |           |               |           |
|--------|----------------------------|---------|---------|-----------|---------------|-----------|
|        | 72 × 72                    | 84 × 84 | 96 × 96 | 108 × 108 | 120 × 120     | 132 × 132 |
| NCM ↑  | 292                        | 297.8   | 298.62  | 300.28    | <b>300.57</b> | 293.75    |
| RMSE ↓ | 1.954                      | 1.978   | 1.975   | 1.977     | 1.988         | 1.983     |

表 4 不同 k 值的 NCM 和 RMSE 结果  
Tab. 4 The NCM and RMSE results for different k

| 指标     | k(固定参数:LC = 5 × 5, DP = 120 × 120) |        |               |        |        |        |
|--------|------------------------------------|--------|---------------|--------|--------|--------|
|        | 1                                  | 2      | 3             | 4      | 5      | 6      |
| NCM ↑  | 173.67                             | 229.34 | <b>300.57</b> | 287.55 | 260.23 | 245.32 |
| RMSE ↓ | 1.999                              | 1.993  | 1.988         | 1.866  | 1.928  | 2.042  |

2.4 对比实验

2.4.1 定性实验

图 3 系统展示了 SIFT、OS-SIFT、RIFT、MLSS、CoFSM、MSHLMO、RDFM、sRIFD 及本文 ELSS 共 9 种算法在 3 个数据集上的匹配性能对比。各子图按从左至右的顺序呈现了 5 组典型跨模态匹配场景:数据集 1 中的 Optical-Optical、Optical-Infrared、Optical-Map;数据集 2 中的 Optical-SAR;数据集 3 中的 Optical-SAR。

定性实验结果表明,图 3(a)的传统 SIFT 及图 3(b)的 OS-SIFT 在多模态遥感匹配任务中适用性受限,仅在个别场景下可建立有限匹配(如 OS-SIFT 在数据集 2 中的 Optical-SAR 结果),对模态差异的敏感性导致其在其他场景的匹配成功率较低,几乎在 5 组示例图片上无法看到密集特征点对连线。图 3(e)的 CoFSM 与图 3(f)的

MSHLMO 虽在部分场景(如数据集 2 中的 Optical-SAR)可获得较多匹配点对连线,但在 Optical-Infrared 和 Optical-Map 等挑战性场景下匹配稳定性欠佳。图 3(c)的 RIFT 和图 3(d)的 MLSS 利用构建的结构特征信息,展现出相对稳健的跨模态匹配能力,但对尺度和旋转变化敏感,因此在 Optical-Optical 类型上连线稀疏,获取正确匹配点对数的能力仍与本文方法存在显著差距。RDFM 方法结合 VGG19 预训练网络与手工描述符,在 Optical-Map 及数据集 2 的 Optical-SAR 任务中实现了精确匹配,但其对旋转变化的敏感性导致在 Optical-Optical 场景性能受限。sRIFD 虽具备旋转不变性设计,却难以克服多模态图像间的非线性辐射差异,通用性不足,在 Optical-Optical 和数据集 3 的 Optical-SAR 任务中出现显著匹配失效。




图 3 不同方法在示例图像上的匹配连线结果

Fig. 3 The matching results of example images for different methods

2.4.2 定量实验

实验分析按 NCM、RMSE 和 SR 3 个核心指标依次展开。作为最简捷有效的评估方法之一，NCM 可量化评估图像配准算法与特征描述符的匹配精度。图 4 和 5 展示了所有对比方法的 NCM 结果。图 4(a) ~ (e) 分别表示数据集 1 中

的 Optical-Optical、Optical-Infrared、Optical-Map、数据集 2 中的 Optical-SAR、数据集 3 中的 Optical-SAR 的 NCM 结果。

首先，从图 5 的整体 NCM 结果可见，所提的 ELSS 方法在不同数据集与数据类型中均保持最优性能。尽管 CoFSM 和 MSHLMO 在特定数据类

型(数据集 1 的 Optical-Map 和数据集 2 的 Optical-SAR)上取得较高 NCM 均值,但二者难以处理多样本跨模态图像的巨大差异,导致 NCM 结果不稳定。RDFM 在分辨率较高且没有几何变化的数

据集 2 上尤其出色,但在不同场景下的剧烈浮动表现降低了其在多模态匹配任务上的鲁棒性。MLSS、OS-SIFT 和 SIFT 方法在多数匹配任务中失效。



图 4 不同图像类型的 NCM 结果  
Fig.4 The NCM results for different image types




图 5 不同方法的 NCM 结果

Fig. 5 The NCM results for different datasets

进一步分析图 4 所示的 50 组图像对的 NCM 详细数据。在各子图中,顶部频数堆叠直方图统计不同方法在各 NCM 区间的分布(颜色区分区间),底部直方图展示对应图像类型的平均 NCM 值。具体而言:图 4(a)表明 ELSS 在 Optical-Optical 图像匹配中具有显著优势,其 50 组图像的 NCM 分布较为均匀;图 4(c)显示虽然 RDFM、RIFT 与 ELSS + FAST 在部分图像对中 NCM 值均超过 400,但 RDFM 和 RIFT 表现不稳定,致使更多图像的 NCM 值低于 100,因此其平均 NCM 值低于 ELSS + FAST;图 4(d)显示 RDFM 在更多图像对中实现了超过 700 的 NCM 值,其平均 NCM

因而达到 733.1 的峰值;然而在图 4(e)中,由于 Optical-SAR 图像间存在非线性辐射差异,RDFM 性能显著下降,该现象凸显了其在多模态场景应用中的主要局限。综合图 4 与图 5 结果可知,ELSS 方法在 MRSI 特征提取与匹配任务中兼具卓越性与稳定性。特别在图 4(b)和(e)中,ELSS + FAST 与 ELSS + BRISK 的 NCM 均值均超过 100,而其他方法因失效图像对数量较多,导致平均 NCM 值不足 50。

表 5 与表 6 分别列出了 RMSE 与 SR 的量化结果。表 5 中加粗标注的为最优值,下划线标注的为次优值。

表 5 不同方法的 RMSE 结果

Tab. 5 The RMSE results for different methods

| RMSE ↓        | Optical-Optical | Optical-Infrared | Optical-Map  | Optical-SAR  | Dataset 1    | Dataset 2    | Dataset 3    |
|---------------|-----------------|------------------|--------------|--------------|--------------|--------------|--------------|
| ELSS + FAST   | <u>1.957</u>    | 2.378            | 2.038        | 2.077        | <u>2.124</u> | 2.028        | 1.987        |
| ELSS + ORB    | 1.968           | 2.720            | 2.009        | 2.315        | 2.233        | <u>2.016</u> | 2.285        |
| ELSS + Harris | 1.968           | 3.432            | 2.026        | 2.351        | 2.475        | 2.044        | 2.002        |
| ELSS + BRISK  | 1.964           | <u>2.377</u>     | 2.035        | <u>2.074</u> | 2.125        | 2.028        | 1.978        |
| sRIFT         | <b>1.938</b>    | <b>2.013</b>     | <b>1.988</b> | <b>1.946</b> | <b>1.980</b> | <u>2.005</u> | <b>1.917</b> |
| RDFM          | 1.978           | 4.338            | <u>2.006</u> | 2.908        | 2.774        | 2.025        | 2.658        |
| MSHLMO        | 3.446           | 16.750           | 4.516        | 6.922        | 8.237        | 2.050        | 3.746        |
| COFSM         | 5.261           | 20               | 20           | 15.595       | 15.087       | 10.981       | 18.560       |
| MLSS          | 9.102           | 3.672            | 2.400        | 4.167        | 5.058        | <b>1.984</b> | <u>1.947</u> |
| RIFT          | 9.356           | 10.644           | 3.429        | 14.103       | 7.810        | 8.140        | 18.206       |
| OS-SIFT       | 11.353          | 20               | 20           | 17.657       | 17.118       | 18.190       | 19.638       |
| SIFT          | 7.985           | 20               | 20           | 16.996       | 15.995       | 20           | 20           |

表 6 不同方法的 SR 结果

Tab. 6 The SR results for different methods

/%

| SR ↑          | Optical-Optical | Optical-Infrared | Optical-Map | Optical-SAR | Dataset 1 | Dataset 2 | Dataset 3 |
|---------------|-----------------|------------------|-------------|-------------|-----------|-----------|-----------|
| ELSS + FAST   | 100             | 98               | 100         | 100         | 100       | 100       | 98        |
| ELSS + ORB    | 100             | 96               | 100         | 100         | 98        | 100       | 96        |
| ELSS + Harris | 100             | 92               | 100         | 100         | 100       | 100       | 92        |
| ELSS + BRISK  | 100             | 98               | 100         | 100         | 100       | 100       | 98        |
| sRIFD         | 100             | 100              | 100         | 100         | 100       | 100       | 100       |
| RDFM          | 98              | 84               | 100         | 100         | 94        | 98        | 84        |
| MSHLMO        | 92              | 18               | 86          | 100         | 90        | 92        | 18        |
| COFSM         | 80              | 0                | 0           | 50          | 8         | 80        | 0         |
| MLSS          | 100             | 98               | 98          | 100         | 100       | 100       | 98        |
| RIFT          | 60              | 52               | 92          | 66          | 10        | 60        | 52        |
| OS-SIFT       | 48              | 0                | 0           | 10          | 2         | 48        | 0         |
| SIFT          | 66              | 0                | 0           | 0           | 0         | 66        | 0         |

相较于其他方法,sRIFD 在 RMSE 和 SR 指标上呈现领先优势,表明该方法能在有限 NCM 值条件下实现优异的匹配精度。然而结合图 3 定性分析发现,sRIFD 的实际性能与量化指标存在偏差,其优势以显著降低 NCM 值(即匹配连线数量较少)为代价,故实际适用性需通过更多数据验证。相比之下,ELSS 展现出显著综合优势。该方法通过秩索引编码器同步提取浅层显著特征并构建深层特征关联,在匹配过程中更有效地融合特征的局部邻域信息,从而提升匹配鲁棒性。尽管其 RMSE 和 SR 结果未呈现 sRIFD 的绝对优势,但综合 3 项评价指标及定性分析表明,ELSS 在多模态图像匹配中具有卓越的稳定性与适应性。同为 LSS 改进方法的 MLSS 在无旋转变化的数据集 2 和 3 中表现尚可,但对于存在明显几何差异的数据集 1,其错误匹配与失效匹配较多,导致 RMSE 显著高于前 2 个数据集。CoFSM、OS-SIFT 和 SIFT 方法检测到的特征数量较少,在某些图像类型上几乎无法实现有效匹配,造成 RMSE 高于 15、SR 低于 20%(正确匹配数不足 10 组)。为多模态多源遥感图像设计的 RIFT 与 MSHLMO 方法虽能部分抵抗强度差异与辐射畸变,但面对不同数据集的场景变化与复杂内容时,其通用性仍存在局限,SR 与 RMSE 的波动性使其性能逊于本文方法。

2.5 消融实验

本研究的核心动机在于将基于图的特征过滤

技术引入描述符构建过程。为明晰方法创新性,本文将其关键技术归纳为 2 点:扩展单元搜索(local cell search, LCS)与基于图的特征过滤(graph-based feature filtering, GBF)。作为对比实验,本文另采用标准值排序(standard valuesorting, SVS)方法替代 GBF 以开发新方法。需特别说明的是,若未采用 LCS 与 GBF 技术,所提方法将退化为 MLSS 方法。GBF、SVS 以及 MLSS 的最大索引法(max index, MAI)均可视为特征选择的不同实现途径。为更直观阐释其差异,实验通过 ELSS + FAST 框架对 5 类数据类型(共计 250 组图像对)开展了系统性实验验证。为了方便叙述,本文设计了以下 5 种方法。

- Method 1:传统 LSS 方法。
- Method 2:MAI 最大索引法,即 MLSS 方法。
- Method 3:LCS + SVS。
- Method 4:LCS + MAI。
- Method 5:LCS + GBF,即 ELSS + FAST。

表 7 的消融实验结果表明,Method 1 在跨模态场景下易受辐射畸变与几何形变的影响,导致其图像对应关系构建能力明显下降。引入 MAI 模块后,Method 2 通过特征点密度优化策略,NCM 指标提升至 56.91,但由于该方法对旋转和尺度变化较为敏感,性能提升仍有限。LCS 模块采用扩展单元计算 LSS 特征,在与 SVS 结合时(Method 3),其排序机制依赖强度信息,易受局部像素强度干扰;而 LCS + MAI 组合时(Method 4),NCM

指标得到显著改善,然而当数据类型增多时,直接采用最大索引替代特征向量的策略可能加剧图像间的强度畸变,从而影响描述符的鲁棒性,降低匹配精度。相比之下,GBF 模块通过图结构建模优化特征筛选过程,在 LSS 特征的基础上构建图模型,刻画扩展单元内特征间的相似性度量,并利用

秩立方结构的前 3 层秩索引构建新的特征向量,有效降低了算法对强度信息的依赖性,增强了多数据类型的适应性。Method 5 (LCS + GBF) 在保持较低 RMSE 和适中运行时间的基础上,该模块将 NCM 指标大幅提升至 276.92,展现了所提方法优异的跨模态匹配性能。

表 7 不同算法的消融实验结果

Tab. 7 The ablation results for different algorithm flows

|                        | LCS | SVS | MAI | GBF | NCM ↑         | RMSE ↓      | 时间/s ↓      |
|------------------------|-----|-----|-----|-----|---------------|-------------|-------------|
| Method 1               |     |     |     |     | 3.80          | \           | <b>1.88</b> |
| Method 2 (MLSS)        |     |     | ✓   |     | 56.91         | 3.82        | 10.36       |
| Method 3               | ✓   | ✓   |     |     | 183.42        | 2.25        | 8.66        |
| Method 4               | ✓   |     | ✓   |     | <u>216.89</u> | <b>2.00</b> | <u>5.87</u> |
| Method 5 (ELSS + FAST) | ✓   |     |     | ✓   | <b>276.92</b> | <u>2.08</u> | 38.08       |

3 结语

本研究提出一种增强型局部自相似性特征描述符 ELSS,采用图结构驱动的特征选择方法构建高鲁棒性描述符。所设计的秩索引编码器有效降低传统 LSS 特征对图像强度的依赖性,秩频率直方图则显著提升特征区分度。3 层秩立方结构保障图滤波过程在噪声与畸变条件下的稳定性。通过结构化秩信息重构传统 LSS 特征,ELSS 在 3 个公开多模态数据集、5 类跨模态匹配场景中均超越对比方法。250 对测试图像的匹配结果表明,ELSS 具有优异的抗辐射畸变与强度变化能力。结合 4 种典型特征检测器后,最高可实现 276.92 的 NCM 值和 2.08 的 RMSE 值。然而,该方法性能仍受限於特征检测精度,制约其与多样化检测器的兼容性。后续研究将聚焦于特征检测器的算法特性分析,以增强 ELSS 的通用适配能力。

参考文献

[1] 徐宇翔,胡庆武,段延松,等. 融合 LiDAR 点云与无人机影像的滑坡动态监测技术[J]. 测绘通报,2024(8):42-47.  
XU Y X, HU Q W, DUAN Y S, et al. Landslide dynamic monitoring technology by integrating LiDAR point cloud and UAV image[J]. Bulletin of Surveying and Mapping, 2024(8): 42-47.

[2] 朱柏,叶沅鑫. 多模态遥感图像配准方法研究综述[J]. 中国图象图形学报,2024,29(8):2137-2161.  
ZHU B, YE Y X. Multimodal remote sensing image

registration: A survey [J]. Journal of Image and Graphics, 2024, 29(8): 2137-2161.

[3] 樊仲藜,张力,王庆栋,等. SAR 影像和光学影像梯度方向加权的快速匹配方法[J]. 测绘学报,2021,50(10):1390-1403.  
FAN Z L, ZHANG L, WANG Q D, et al. A fast matching method of SAR and optical images using angular weighted orientated gradients[J]. Acta Geodaetica et Cartographica Sinica, 2021, 50(10): 1390-1403.

[4] 张浩,马佳义,樊凡,等. 基于特征空间多分类对抗机制的红外与可见光图像融合[J]. 计算机研究与发展,2023,60(3):690-704.  
ZHANG H, MA J Y, FAN F, et al. Infrared and visible image fusion based on multiclassification adversarial mechanism in feature space[J]. Journal of Computer Research and Development, 2023, 60(3): 690-704.

[5] 彭韬,杨培臻,周亮,等. 一种旋转和尺度不变的异源景象匹配方法[J]. 弹箭与制导学报,2024,44(5):38-46.  
PENG T, YANG P Z, ZHOU L, et al. A rotation and scale invariant heterogeneous sence matching approach [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2024, 44(5): 38-46.

[6] 孙彬,游航,李文博,等. 双光载荷图像融合及其在低空遥感中的应用[J]. 航空学报,2025,46(11):58-81.  
SUN B, YOU H, LI W B, et al. Dual-band payload image fusion and its applications in low-altitude remote sensing[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(11): 58-81.

[7] 唐霖峰,张浩,徐涵,等. 基于深度学习的图像融合方法综述[J]. 中国图象图形学报,2023,28(1):3-36.

- TANG L F, ZHANG H, XU H, et al. Deep learning-based image fusion: A survey [J]. *Journal of Image and Graphics*, 28(1): 3-36.
- [8] YE Y X, TANG T F, ZHU B, et al. A multiscale framework with unsupervised learning for remote sensing image registration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5622215.
- [9] 叶沅鑫,孙苗苗,王蒙蒙,等. 结合邻域信息和结构特征的遥感影像变化检测[J]. *测绘学报*, 2021, 50(10): 1349-1357.
- YE Y X, SUN M M, WANG M M, et al. Change detection of remote sensing images by combining neighborhood information and structural features[J]. *Acta Geodaetica Cartographica Sinica*, 2021, 50(10): 1349-1357.
- [10] 叶沅鑫,王蒙蒙,杨超,等. 基于方向相位稠密特征的多传感器遥感影像配准方法和系统[J]. *遥感学报*, 2024, 28(6): 1525-1538.
- YE Y X, WANG M M, YANG C, et al. A multi-sensor remote sensing registration method and system based on dense feature of orientated phase[J]. *National Remote Sensing Bulletin*, 2022, 28(6): 1525-1538.
- [11] XIANG Y M, WANG F, YOU H J. OS-SIFT: A robust SIFT-like algorithm for high-resolution optical-to-SAR image registration in suburban areas[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3078-3090.
- [12] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [13] YE Y X, SHEN L, HAO M, et al. Robust optical-to-SAR image matching based on shape properties[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(4): 564-568.
- [14] XIONG X, XU Q, JIN G W, et al. Rank-based local self-similarity descriptor for optical-to-SAR image matching[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(10): 1742-1746.
- [15] LI J Y, HU Q W, AI M Y. RIFT: Multi-modal image matching based on radiation-variation insensitive feature transform[J]. *IEEE Transactions on Image Processing*, 2020, 29: 3296-3310.
- [16] HONG Y M, LENG C C, ZHANG X Y, et al. Max-index based local self-similarity descriptor for robust multi-modal image registration[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4505805.
- [17] YAO Y X, ZHANG Y J, WAN Y, et al. Multi-modal remote sensing image matching considering co-occurrence filter[J]. *IEEE Transactions on Image Processing*, 2022, 31: 2584-2597.
- [18] LI J Y, HU Q W, ZHANG Y J. Multimodal image matching: A scale-invariant algorithm and an open dataset[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 204: 77-88.
- [19] SHECHTMAN E, IRANI M. Matching local self-similarities across images and videos [C] // 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis: IEEE, 2007: 1-8.
- [20] ROFFO G, MELZI S, CASTELLANI U, et al. Infinite feature selection: A graph-based feature filtering approach[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(12): 4396-4410.
- [21] ROSTEN E, DRUMMOND T. Machine learning for high-speed corner detection [C] // Proceedings of the 9th European Conference on Computer Vision. Graz: ACM, 2006: 430-443.
- [22] RUBLEE E, RABAU D V, KONOLIGE K, et al. ORB: An efficient alternative to SIFT or SURF [C] // 2011 International Conference on Computer Vision. Barcelona: IEEE, 2012: 2564-2571.
- [23] HARRIS C G, STEPHENS M. A combined corner and edge detector [C] // Proceedings of the Alvey Vision Conference. Manchester: Alvey Vision Club, 1988: 1694378.
- [24] LEUTENEGGER S, CHLI M, SIEGWART R Y. BRISK: Binary Robust invariant scalable keypoints [C] // 2011 International Conference on Computer Vision. Barcelona: IEEE, 2012: 2548-2555.
- [25] XIANG Y M, TAO R S, WANG F, et al. Automatic registration of optical and SAR images via improved phase congruency model[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 5847-5861.
- [26] HUANG M Y, XU Y, QIAN L X, et al. The QXS-SAROPT dataset for deep learning in SAR-optical data fusion[EB/OL]. (2021-04-25) [2025-09-20]. <https://arxiv.org/abs/2103.08259>.
- [27] LI J Y, XU W Y, SHI P C, et al. LNIFT: Locally normalized image for rotation invariant multimodal feature matching[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5621314.
- [28] LI Y, LI B H, ZHANG G H, et al. sRIFD: A shift rotation invariant feature descriptor for multi-sensor image matching [J]. *Infrared Physics & Technology*, 2023, 135: 104970.

[29] CAO F Z,SHI T X, HAN K Y, et al. RDFM: Robust deep feature matching for multimodal remote-sensing images[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 6009605.

scale histogram of local main orientation for remote sensing image registration[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5626714.

[30] GAO C Z, LI W, TAO R, et al. MS-HLMO: Multi-

(编辑 李 静)

作者简介



冷成财,博士(后),西北大学数学学院教授,统计系主任,博士生导师。主要从事数据处理与统计分析、计算机视觉与模式识别等研究,主持国家自然科学基金、中国博士后基金等 10 余项。以第一或通讯作者及合作身份发表学术论文 80 余篇,包含 *IEEE TIP*、*IEEE TNNLS* 等多篇顶级论文,其中 SCI 收录 40 余篇。担任 *Computers and Electrical Engineering* (2018)和 *Remote Sensing* (2021—2023)客座编辑。中国人工智能学会科普委员,中国人工智能学会青工委委员,全国工业统计学教学研究会理事。2017 年入选西北大学“青年学术英才支持计划”,2018 年获陕西高等学校科学技术奖一等奖(第三完成人),2019 年获陕西省科学技术奖二等奖(第四完成人),2023 年和 2025 年被评为西北大学优秀硕士学位论文指导老师,2025 年度获陕西高等学校科学技术研究优秀成果奖二等奖(第一完成人)。