

高分高光谱遥感图像计算成像：从融合到光谱超分

孙卫东¹, 韩晓琳²

1. 清华大学 电子工程系, 北京 100084;

2. 北京理工大学 机电学院, 北京 100081

摘要：高空间分辨率高光谱遥感图像可同时提供丰富的空间与光谱信息，对精准农业、环境监测、目标识别等实际应用极为重要。由于光谱分辨率与空间分辨率之间存在固有矛盾，现有光学遥感成像系统无法同时兼顾高空间分辨率与高光谱分辨率成像的实际需求。计算成像作为重建高分高光谱图像的重要技术手段之一，可将同区域同时相低分高光谱图像作为光谱先验，依据成像模型，将其与高分多光谱图像所具有的空间信息相融合；亦可将图像对库或光谱库作为先验信息进行某种形式的学习，通过光谱映射实现高分高光谱图像的光谱超分辨率重建。因此，本文首先针对上述不同的高分高光谱图像计算成像途径，构建了一种基于先验信息的高分高光谱图像计算成像统一模型；并根据先验信息的不同来源，综述了从低分高光谱与高分多光谱图像融合、到基于图像对库学习的高分高光谱图像光谱超分、再到基于光谱库学习的高分高光谱图像光谱超分的发展过程及其代表性方法，系统分析了现有各类算法的原理、优势与局限性；最后，分析总结了高分高光谱遥感图像计算成像所面临的挑战及未来可能发展方向。结果表明：高分高光谱图像计算成像是突破光学遥感成像系统物理局限的有效途径之一，将融合与光谱超分纳入到一个统一框架有利于系统梳理先验信息的不同来源，形成更具针对性的高精度、高稳定超分辨率重建。本研究为高质量高分高光谱图像计算成像提供了一个统一框架与技术途径，明确了光学遥感图像融合与光谱超分技术的未来发展方向，有望进一步改善其精细结构检测与精细光谱识别能力，从而为后续高精度与高可靠光谱目标检测、地物分类等应用任务提供技术支撑。

关键词：遥感，高分高光谱图像，计算成像统一模型，高分多光谱图像，图像对库，光谱库

中图分类号：TP715/P2

引用格式：孙卫东, 韩晓琳. 2025. 高分高光谱遥感图像计算成像：从融合到光谱超分. 遥感学报, 29(6): 1636–1648

Sun W D and Han X L. 2025. Computational imaging of high-spatial-resolution hyperspectral remote sensed images: From fusion to spectral super-resolution. National Remote Sensing Bulletin, 29(6): 1636–1648 [DOI: 10.11834/jrs.20254209]

1 引言

近年来，中国发射了多种对地观测与海洋观测用系列遥感卫星，其中所获取的高光谱遥感图像在提供精细地物空间信息的同时，也提供了丰富的光谱信息（童庆禧等，2016），具有很好的地物检测与辨识能力，已被广泛应用于环境监测、地表地物分类（Yao等，2023；Sun等，2023）、光谱目标检测（Zhang等，2024a）和水面异常检测（Wang等，2023；Ren等，2024）等多个领域。

然而从光学成像原理上讲，现有光学系统无

法同时兼顾高空间分辨率与高光谱分辨率成像的实际需求，实际应用中更易获取的是低空间分辨率高光谱图像（低分高光谱图像）与高空间分辨率多光谱图像（高分多光谱图像）。究其原因是在光学遥感图像成像过程中，随着光谱波段数的增加，每条光谱波段所对应的带宽变窄（何明一等，2013），因此需要采用较大的瞬时视场才能积累足够多的光子以维持较高的成像信噪比（Akhtar等，2014；Li等，2021）。与仅包含少数几个光谱波段的多光谱图像相比，空间分辨率、光谱分辨率和信噪比的相互制约导致高光谱遥感图像的空间分

收稿日期：2024-05-29；预印本：2025-03-12

基金项目：国家自然科学基金（编号：41971294, 82471999）；北京信息科学与技术国家研究中心跨媒体智能专项资助项目（编号：BNR2019TD01022）；北京理工大学青年教师学术启动计划

第一作者简介：孙卫东，研究方向为空间信息处理与应用、图像处理、模式识别。E-mail: wdsun@tsinghua.edu.cn

通信作者简介：韩晓琳，研究方向为遥感图像处理、模式识别、字典学习与深度学习。E-mail: hxl@bit.edu.cn

分辨率进一步降低, 而较低的空间分辨率限制了其在实际应用能力, 尤其是在地物分类、目标识别等任务中的应用精度。具有更高空间分辨率的多光谱图像有利于提供上述应用任务所涉及的精细空间结构信息, 但其光谱信息的严重匮乏又制约了其在农作物分类、矿物识别等涉及精细光谱信息应用任务中的可适用性。因此, 如何利用实际更易获取的低分高光谱或高分多光谱图像, 依据严格的光学成像模型, 引入各类可能的先验信息, 通过计算成像的手段恢复重建高分高光谱图像是解决上述矛盾的有效途径之一, 也是近年来遥感图像处理领域的热门研究方向。

一般来讲, 计算成像可将同区域同时相低分高光谱图像作为光谱先验, 依据成像模型, 将其与高分多光谱图像所具有的空间信息相融合; 亦可将图像对库或光谱库作为先验信息进行某种形式的学习, 通过光谱映射实现高分高光谱图像的光谱超分辨率重建。但由于现有方法在构建通用高分高光谱图像计算成像框架、先验信息可引入种类等方面研究尚少, 因此, 本文将针对上述不同的高分高光谱图像计算成像途径, 给出基于先验信息的高分高光谱图像计算成像的统一模型; 后根据先验信息的不同来源, 综述从低空间分辨率高光谱与高空间分辨率多光谱图像融合、到基于图像对库学习的高分高光谱图像光谱超分、再到基于光谱库学习的高分高光谱图像光谱超分的发展过程及其代表性方法, 系统分析现有各类算法的原理、优势与局限性; 最后, 分析总结高分高光谱图像计算成像所面临的挑战及未来可能发展方向, 以期高质量高分高光谱图像计算成像提供一个统一框架与技术途径, 从而为后续精细结构检测与精细光谱辨识提供技术支撑。

2 高分高光谱图像计算成像统一框架

本文将由更易获取的高分多光谱图像 $Y \in \mathbb{R}^{\lambda_y \times N}$ 作为输入, 恢复重建高分高光谱图像 $X \in \mathbb{R}^{\lambda_x \times N}$ 的过程, 建模为如下先验信息引导下的

$$X = f(Y|Z) \quad (1)$$

式中, $f(\cdot)$ 表示高分高光谱图像计算成像过程, $Z \in \mathbb{R}^{\lambda_z \times M}$ 为先验信息, N 表示 X 和 Y 中各波段所含像元个数, λ_x 和 λ_y ($\lambda_x \gg \lambda_y$) 分别表示 X 和 Y 中的光谱波段数。如果先验信息 Z 为同区域同时相的

低分高光谱图像, 即 $\lambda_z = \lambda_x$ 、 $M \ll N$, 则先验信息引导下的

高分高光谱图像计算成像等价于传统的多光谱与高光谱图像融合。多光谱与高光谱图像融合是指通过综合汇集同区域、同时相多光谱图像与高光谱图像间互补的空间与光谱信息, 合成高分高光谱图像的方法。一般来讲, 多光谱与高光谱图像融合应同时注重多光谱图像的空间信息保持能力、以及高光谱图像的光谱信息保持能力。现有方法大致可以划分为基于字典学习、基于贝叶斯、基于张量分解、以及基于深度学习的高分高光谱图像融合方法等4大类别。

如果式(1)中的先验信息 Z 为光谱库等提供的光谱信息, 即 $\lambda_z \geq \lambda_x$, 则先验信息引导下的

高分高光谱图像计算成像等价于基于光谱库的高光谱图像光谱超分。高光谱图像光谱超分是指针对高分多光谱图像, 依据光谱稀疏特性, 利用光谱库提供的光谱先验信息形成光谱字典, 由多光谱到高光谱进行光谱分辨率提升, 进而恢复重建高分高光谱图像的过程, 目前现有方法包括基于通用光谱库、基于私有光谱库以及针对非完备光谱覆盖的方法。前两种方法侧重于利用不同类别的光谱库, 形成更高质量的光谱字典, 后者旨在针对高光谱响应函数的非完备覆盖问题, 进一步提升了光谱字典的生成精度。

于单帧多光谱图像的高分高光谱图像计算成像,也有利于研制轻小型化的高光谱计算成像设备。据式(1)中不同先验信息,图1为从图像融合到光谱映射、再到光谱超分的高分高光谱图像计算成像总体框架。




图1 高分高光谱图像计算成像总体框架

Fig. 1 Total framework of the high-resolution hyperspectral computational imaging

3 多光谱与高光谱图像融合方法

现有多光谱与高光谱图像融合方法大致可以分为基于字典学习、基于贝叶斯、基于张量分解、以及基于深度学习的融合方法等4大类别。

3.1 基于字典学习的融合方法

根据所采用字典类型的不同,基于字典学习的多光谱与高光谱图像融合方法又可细分为基于空间字典、基于光谱字典、以及基于空间与光谱联合字典的融合方法。

在基于空间字典的融合方法中,Grohnfeldt等(2013)将多光谱与高光谱图像融合分解为多个全色与多光谱图像融合过程,提出了一种基于全色锐化的多光谱与高光谱图像融合方法。该方法将多光谱与高光谱图像空间分块,利用从多光谱图像块中学习得到的空间字典重建高分高光谱图像。但该算法中全局空间字典学习会导致计算复杂度上升,此外,光谱畸变也是该类方法难以解决的核心难点问题之一。为了进一步改善融合性能并降低计算复杂度,Zhao等(2016)提出了一种稀疏框架下基于协同表示的多光谱与高光谱图像融合方法。该方法利用由多光谱图像块构成的局部自适应空间字典提升高光谱图像的空间分辨率。

与全局字典相比,局部自适应字典的规模要小得多,从而减少了图像融合过程中的计算成本。

为了更高精度保持重建图像中的光谱信息,基于光谱字典的方法被广泛用于高分高光谱图像融合重建中。基于线性混合像元分解模型(Keshava和Mustard, 2002),Yokoya等(2012)提出了一种基于联合非负矩阵分解的图像融合方法,将高光谱图像分解为丰度和端元,该端元矩阵可视为光谱字典的一种特殊形式。其中,由端元矩阵构成的光谱字典具有非负特性,由丰度矩阵构成的系数矩阵具有非负与归一化特性。Huang等(2014)提出了一种基于光谱字典的图像融合方法,其光谱字典由低分高光谱图像学习获得。Simoes等(2015)提出了一种基于总变分正则化的多光谱与高光谱图像融合方法,其光谱字典由端元光谱向量构成。Akhtar等(2014)提出了空间-光谱稀疏表示方法,在非负约束、以及相似光谱具有相同丰度约束下,所求解的光谱字典列具有纯净光谱特性。利用近邻光谱相似性,Dong等(2016)提出了一种基于非负结构化稀疏表示的融合方法,以提高高分高光谱图像的融合质量。Dian等(2019b)提出了一种基于空间光谱稀疏表示的多光谱与高光谱图像融合方法,通过利用非局部空间自相似性、光谱解混先验知识和稀疏先验,从低分高光谱与高分多光谱图像中估计非负光谱字典与具有非负与归一化特性的系数矩阵。将端元矩阵作为一种广义光谱字典,Zhou等(2020)提出了一种基于线性高光谱分解的迭代非负矩阵分解融合方法。该方法在线性混合像元分解模型下,以多光谱图像为约束分别优化高光谱和多光谱图像的端元字典与丰度矩阵,从而重建高分高光谱图像。考虑到上述基于光谱解混的非负矩阵分解方法存在端元数量不确定、非负限制导致计算复杂度较高等问题,Han等(2017)提出了一种基于非分解稀疏表示与字典学习的图像融合方法。与线性混合像元分解模型中具有物理含义的“纯净”端元相比,该方法中光谱字典的每个列向量不再具有具体物理意义,可看作是一个“广义”的端元。利用低空间分辨率高光谱图像构建光谱字典,该方法在无负约束与归一化约束下利用多光谱图像提供的空间信息估计稀疏系数,有效提升了融合精度与融合效率。Xing等(2022)提出了一种基于光谱字典学习的图像融合方法,

其光谱字典由高光谱图像学习获得。该方法首先利用卷积稀疏字典学习算法对光谱字典进行训练, 提取高光谱图像的光谱信息; 其次, 将低分高光谱与高分多光谱图像映射到高分高光谱图像空间, 并构建了卷积稀疏融合模型。与传统的基于图像块的融合方法不同, 该方法通过对整幅图像处理, 抑制了对图像块进行稀疏编码时对场景细节保留的限制。利用光谱字典, Zhang等(2023)提出了一种基于加权核范数的图像融合方法。该方法在集成了小波神经网络、稀疏先验和变分正则化的统一框架下, 利用L1范数提高融合图像的光谱稀疏性, 利用变分正则化保持融合图像的空间分段平滑结构。

与上述采用单一空间或光谱字典的融合方法不同, Nezhad等(2016)提出了一种基于光谱解混与稀疏编码的融合方法, 其光谱字典由低分高光谱图像的端元光谱构成, 空间字典由同一场景高分多光谱和无关场景全色图像块获得。为了同时利用空间与光谱信息, Tian等(2018)构建了双源空间—光谱字典对, 用于充分表征高分多光谱和低分高光谱图像的空间和光谱特征。该方法将多光谱与高光谱图像对划分为立体图像块, 并将其张成二维矩阵; 然后, 通过字典学习多光谱与高光谱立体图像块中的光谱与空间信息, 进而在协同表示框架下重建高分高光谱图像。为了进一步提升兼具空间与光谱特征字典的表达能力, Yi等(2018)提出了一种利用空间和光谱相关性以及自适应正则化的多光谱与高光谱图像融合方法。该方法利用多光谱图像训练的高空间分辨率字典来表达空间信息, 通过线性光谱解混来保持高空间分辨率和低空间分辨率高光谱图像之间的光谱相关性, 通过引入低秩特性对各波段在同一区域提取的高光谱图像块矩阵进行正则化, 并将其作为空间约束, 进一步减少了图像融合中的光谱失真。考虑到仅利用光谱字典不足以保留空间信息, 仅利用空间字典会带来较大的光谱畸变, Han等(2020)提出了一种基于优化双字典的多光谱与高光谱图像融合方法。该方法利用低分高光谱和高分多光谱图像提供的光谱信息在分裂思想下优化求解光谱字典和光谱稀疏系数, 再利用低分高光谱和高分多光谱图像提供的剩余空间信息, 在图像块形式下优化求解空间字典及其相应的稀疏系数, 通过综合利用光谱与空间信息, 实现了

高分高光谱图像的高精度融合重建。可以看出, 如何最大程度地兼顾空间与光谱信息的完整性是该类方法面临的核心问题。

3.2 基于贝叶斯的融合方法

基于贝叶斯的融合方法依据图像信息在观测场景中的先验分布, 如高斯先验, 通过构建多种估计器对高分高光谱图像进行估计(Wei等, 2014)。通过求解与贝叶斯估计器有关的西尔维斯特方程, Wei等(2015)提出了一种基于变分法的快速多光谱与高光谱图像快速融合方法。该方法将待重建图像投影到低维子空间中, 利用从高光谱图像中学习到的光谱字典, 在稀疏约束下利用交替方向乘子法 ADMM (Alternating Direction Method of Multipliers) (Boyd等, 2011) 求解稀疏系数。Sui等(2019)提出了一种基于非参贝叶斯估计的多光谱与高光谱图像融合方法, 构建每个潜在变量的概率分布模型。该方法首先将低分高光谱与高分多光谱图像投影到低维子空间中, 并将其作为训练数据集, 通过贝叶斯非参数方法与 β -伯努利过程学习字典与稀疏系数, 并通过吉布斯抽样计算后验分布。然后, 将获得的后验分布作为先验, 利用ADMM优化求解字典与系数矩阵。考虑到实际应用中, 不同时刻成像通常会由于光照、大气效应等原因造成光谱特征显著变化, 且光谱域和空间域的退化过程是未知的, Ye等(2022)提出了一种针对光谱特征变化的贝叶斯融合方法。该方法将上采样的低分高光谱图像视为待重建高分高光谱图像的低频分量, 利用混合高斯函数表征高频纹理, 可自适应地拟合复杂的光谱变异特性。不难看出, 对于基于贝叶斯的图像融合方法而言, 概率先验与实际场景的吻合程度是制约其融合重建质量的关键。

3.3 基于张量的融合方法

张量作为矩阵的高阶扩展, 可以同时表达高分高光谱三维立方体的空间域与光谱域结构。为了保留高分高光谱图像中的空间与光谱结构, Zhang等(2018)提出了一种基于空间—光谱—图—正则化低秩张量分解的图像融合方法, 将融合问题转化为具有图正则化约束的低秩张量分解问题。该方法基于高分多光谱图像的空间一致性、低分高光谱图像的光谱平滑性构建空间图与光谱

图,并将其作为正则化约束引入低秩张量分解中,从而保留融合重建高分高光谱图像的空间相关性和光谱结构。基于 Tucker 分解, Li 等 (2018) 提出了一种基于耦合稀疏张量分解的图像融合方法,将图像融合问题定义为核张量 (core tensor) 和 3 种模式字典的估计问题。该方法在核张量稀疏约束下,利用低分高光谱图像的光谱信息与高分多光谱图像的空间信息迭代求解 3 个字典与核张量。相似地, Dian 等 (2019a) 将多光谱与高光谱图像融合问题转化为张量—训练低秩 LTTR (Low Tensor-Train Rank) 约束下的优化问题。该方法先将高分多光谱图像聚类为多组,并构成模态高度相关四维张量;然后,对四维张量施加 LTTR 约束用于学习空间模态、光谱模态和非局部模态间的相似性,并采用 ADMM 迭代求解,从而重建高分高光谱图像。利用高光谱图像的空间—光谱相关性以及非局部相似性, Yuan 等 (2020) 提出了基于非凸低秩张量和全变分正则化的图像融合方法。该方法建立了基于拉普拉斯的低秩模型,利用二阶变分描述空间域与相邻波段的局部平滑结构,并采用迭代重加权核范数算法进行优化求解,进一步提升了多光谱与高光谱图像融合质量。基于张量环, Chen 等 (2022b) 提出将多光谱与高光谱图像融合问题转化为张量环因子优化估计问题。该方法在张量环分解中引入因子平滑正则化,从而保证高分高光谱图像的空间与光谱维连续性,同时设计了一种高效的邻域交替极小化算法来求解该模型。基于 CP (canonical polyadic) 分解, Zeng 等 (2024) 提出了一种基于贝叶斯非局部张量分解的多光谱与高光谱图像融合方法。该方法将 CP 分解应用于高分高光谱图像的非局部张量,以更好地捕捉高分高光谱图像的低秩性。然后,该方法利用稀疏贝叶斯框架求解 CP 分解中的秩,并采用 ADMM 迭代求解最大后验估计器优化,从而进行参数估计。

3.4 基于深度学习的融合方法

目前,深度学习在计算机视觉领域取得显著进展 (LeCun 等, 2015),受此启发,基于深度学习的多光谱与高光谱图像融合方法也被陆续提出。基于低分高光谱图像与待重建高分高光谱图像的光谱奇异向量 (spectral singular vector) 相同这一假设, Palsson 等 (2017) 提出了一种基于三维卷

积神经网络 3D-CNN (Three Dimension Convolutional Neural Network) 的融合方法。该方法在融合阶段之前使用主成分分析降低了高光谱图像的光谱维度从而提高融合效率,并通过 3D-CNN 自动学习空间抽取滤波器,将高分多光谱和低分高光谱图像融合为高分高光谱图像。受 CNN 网络的启发, Yang 等 (2018) 提出了一种基于两支路深度卷积神经网络 (deep convolutional neural network) 的多光谱与高光谱图像融合方法。该方法通过两个支路分别提取空间与光谱特征,并在全连接层 (fully connected layer) 进行融合,从而获得高分高光谱图像。基于光谱映射关系在不同空间分辨率上的不变性这一假设, Han 等 (2019a) 提出了一种基于多分支神经网络反向传播神经网络 BPNN (Back Propagation Neural Network) 的图像融合方法。该方法在低空间分辨率下利用无监督聚类方法,按光谱相关性将低分多光谱图像分到若干以类为基准的子空间中,分别利用相应子空间中多光谱与高光谱向量组成的光谱对,通过多路 BPNN 建立针对不同子空间的非线性光谱映射模型;再在高空间分辨率下,利用关联聚类方法将高分多光谱图像划分到已确定的子空间中,并将已训练的相应非线性光谱映射模型应用于高分多光谱图像,从而获得融合重建后的高分高光谱图像。为了充分挖掘高分多光谱图像的空间信息, Zhou 等 (2019) 提出了一种基于金字塔完全卷积神经网络 (pyramid fully convolutional neural network) 的图像融合方法。该方法中,编码器子网络通过卷积核提取低分高光谱图像中的光谱信息,并将其编码为中间结果;金字塔融合子网络利用该中间结果与高分多光谱图像作为输入,从全局到局部逐步重建高分高光谱图像。Huang 等 (2022) 提出了一种基于拉普拉斯金字塔和卷积神经网络的多光谱与高光谱图像融合方法。首先,利用低分高光谱和高分多光谱图像对,该方法通过线性回归算法计算初始高分高光谱图像;然后,通过初始高分高光谱图像与 CNN 生成的模糊图像的插值级联提取空间高频细节,通过光谱角误差与均方误差的加权组合约束空间与光谱损失,该方法实现了稳定重建高分高光谱图像的目的。考虑到现有融合方法难以同时捕获远程依赖关系与细粒度空间特征, Zhang 等 (2023) 提出了一种基于多尺度注意力网络的图像融合方法。该方法由多尺度注意力模块、

空间信息聚合模块和光谱注意力模块构成。通过多尺度注意力模块自适应捕获远程依赖关系与局部粒度信息, 通过空间信息聚合模块和光谱注意力模块提取空间与光谱信息, 该方法显著提高了融合性能。考虑到空间维与光谱维退化信息在真实应用场景下获取难度较高, Cao等(2024)提出了一种基于transformer网络与卷积神经网络混合结构的图像融合方法。该方法中, 基于CNN的空间退化网络通过结构退化与平滑退化的双路径结构表达空间退化过程, 基于CNN的光谱退化网络利用一维卷积层提取光谱退化中的平滑与稀疏特征, 从而提高了其在复杂现实环境下的退化表达能力, 基于transformer的特征提取网络融入分层空间-光谱特征, 从而保证重建高分高光谱图像空间与光谱上的交叉相似性。不难看出, 大量的训练数据、较长的训练时间、以及训练模型固有的数据依赖性制约该类融合方法实际应用范围的关键之所在。

4 高分高光谱图像光谱超分方法

现有基于图像对库或光谱库先验下的高分高光谱图像光谱超分方法大致可以分为基于字典学习、以及基于深度学习的光谱超分方法等两大类。

4.1 基于字典学习的光谱超分方法

基于字典学习的光谱超分方法又可细分为基于附加高光谱图像与基于光谱库的方法。前者侧重于在附加低分高光谱图像的条件下, 实现由高分多光谱图像到高分高光谱图像的光谱超分, 但与前面所综述融合方法的最大不同点在于, 这里所附加的高光谱图像不严格要求与多光谱图像满足同区域、同时相条件, 因此更具普适性; 后者则依据遥感图像的光谱稀疏特性、以及光谱库对地物光谱的全覆盖特性, 利用光谱库所提供的光谱信息构建光谱字典, 并在此基础上实现多光谱到高分高光谱图像的光谱超分重建。

在基于附加高光谱图像的光谱超分方法中, 将构建的自然场景高光谱图像数据库作为光谱先验, Arad和Ben-Shahar(2016)提出了一种基于稀疏表示的光谱超分方法, 由多光谱图像的特殊形式——RGB图像恢复重建高分高光谱图像。该方法利用K奇异值分解K-SVD(K-singular Value

Decomposition)算法(Aharon等, 2006)训练光谱字典挖掘自然场景高光谱图像数据库中的光谱先验信息, 由正交匹配追踪(greedy orthogonal matching pursuit)算法(Rubinstein等, 2008)获取稀疏系数。为了进一步提高重建高分高光谱图像的质量和运行效率, Wu等(2017)在有效改进上述方法的同时, 提出了一种基于A+方法(Timofte等, 2014)的浅层学习光谱超分辨率方法。利用Arad等构建的自然场景高光谱图像数据库作为光谱先验, 该方法优化求解了一个包含低-高分光谱分辨率的稀疏字典对, 并利用局部欧几里德线性关系计算从RGB图像到高分高光谱图像的投影矩阵, 从而重建高分高光谱图像。将相似场景高光谱图像作为光谱先验信息, Han等(2017)所提方法也可用于高分高光谱图像光谱超分。该方法通过K-SVD算法利用多帧相似场景下的低分高光谱图像进行光谱字典学习, 并将学习得到的光谱字典用于高分高光谱图像稀疏表达, 实现了由高分多光谱图像到高分高光谱图像的光谱超分辨率重建。在稀疏表示和字典学习框架下, 利用附加高光谱图像训练耦合光谱字典, Fotiadou等(2019)提出了一种基于耦合字典学习模型的光谱超分方法。将其他场景多光谱与高分高光谱图像对作为先验信息, Yi等(2019)提出了一种稀疏表示框架下的高光谱图像光谱超分方法。该方法利用其他场景多光谱与高分高光谱图像对估计高分多光谱与待重建高分高光谱图像间的光谱映射关系; 然后, 由其他场景高分高光谱图像学习光谱字典, 并在非负与归一化约束下优化求解其稀疏系数; 最后, 将低秩特性作为全局光谱约束重建高分高光谱图像。利用现有高分高光谱图像作为光谱先验, Chang等(2021)提出了一种基于PCA字典的多光谱图像光谱信息恢复重建方法。将多光谱与高分高光谱图像重叠区域作为光谱先验, Gao等(2021)提出了一种联合稀疏与低秩学习方法, 用于实现非重叠区域的高光谱图像光谱超分。该方法利用重叠区域联合学习低秩多光谱与高分高光谱字典对, 在稀疏约束下恢复重建高分高光谱图像的光谱信息。

自20世纪70年代以来, 不同机构逐渐建立和完善了许多光谱数据库(spectral library), 如美国地质调查局USGS(United States Geological Survey)(Clark等, 2007)、喷气推进实验室JPL(Jet Propulsion Laboratory)(Meerdink等, 2019)、约翰霍普金斯

大学JHU (Johns Hopkins University) (Salisbury等, 1991)等。目前, 光谱库已广泛用于混合端元分解 (Xu等, 2016; Ertürk等, 2016)、高光谱图像分类 (Lacerda等, 2016; Ouerghemmi等, 2017)、及ENVI等商业软件中。考虑到多光谱成像中丢失的光谱信息可以利用光谱库加以恢复, 即在光谱库辅助下, 可以通过高分多光谱图像恢复重建出高分高光谱图像, Han等 (2019b) 提出了一种基于光谱库字典学习的光谱超分方法, 将多光谱到高光谱的光谱映射关系以字典的形式加以表示。该方法首先利用波段匹配, 将光谱库映射为与待重建高光谱图像波段相对应的特定光谱库; 再将该光谱库作为训练数据, 通过K-SVD算法学习得到匹配后的光谱字典; 利用高分多光谱图像提供的空间信息, 通过ADMM算法获得相应的稀疏系数。该算法在光谱库的辅助下, 仅利用一幅高分多光谱图像即可实现高分高光谱图像的重建。同样将光谱库作为光谱先验信息, Sha等 (2022) 提出了一种基于线性光谱混合模型的光谱超分辨率方法, 由多光谱图像重建高光谱图像。基于线性混合模型, 该方法首先将高分多光谱图像光谱解混为表示端元的光谱字典与丰度矩阵, 然后从光谱库中选择相应光谱端元用于表达高光谱图像, 最后将光谱端元与丰度线性混合重建高光谱图像。将开源光谱库作为主要高光谱信息源, Yan等 (2023) 提出了一种基于字典学习的光谱超分方法。该方法先将开源光谱库映射为特定光谱库, 通过融合多光谱图像的空间信息和特定光谱库的高光谱信息, 得到中间结果; 然后, 从中间结果中学习可以表达高光谱图像光谱信息的低秩光谱字典, 并在非负约束下求解表达多光谱图像的稀疏系数; 最后通过低秩光谱字典与稀疏系数的乘积获得高分高光谱图像。Han等 (2024) 提出了一种基于光谱库非完全覆盖条件下的光谱超分辨率方法, 该方法以光谱库为先验, 首先提出了一种典型光谱集构建策略; 其次, 在稀疏与低秩约束框架下, 通过先验光谱库优化学习光谱字典, 通过高分多光谱图像提供的空间信息以及典型光谱集提供的光谱相似度约束, 采用ADMM算法优化相应的系数矩阵; 最后, 利用优化后的光谱字典及其系数矩阵重构高分高光谱图像。有鉴于光谱库的完备性问题, 近期, Leng等 (2024) 提出了一种基于通用和私有联合光谱库的光谱超分辨率方法, 该

方法将由感兴趣地物光谱组成的私有光谱库引入通用光谱库, 形成新的联合光谱库, 利用联合光谱库构建新的光谱超分辨率模型; 并通过加权因子平衡通用与私有库在光谱字典构建中的作用, 极大提升了基于光谱库光谱超分方法的应用精度。

4.2 基于深度学习的光谱超分方法

将大量由多光谱 (或RGB) 图像与高光谱图像所组成的图像对作为先验信息, 基于深度学习的光谱超分方法得到了广泛研究 (Mei等, 2021; He等, 2023)。具体而言, 通过构建公开高光谱图像数据集, Nguyen等 (2014) 提出了一种基于径向基函数网络 (radial basis function network) 的光谱超分方法, 利用白平衡与网络学习实现不同亮度条件下的高光谱图像恢复重建。利用公开多光谱-高光谱数据集, Galliani等 (2017) 提出了一种基于56层CNN的光谱超分方法, 更为准确地建立了从RGB图像到高光谱图像的光谱映射关系。为了证明浅层学习也能达到相当的光谱超分性能, Can和Timofte (2018) 提出了一种基于残差块 (residual blocks) 的浅层CNN方法用于实现高分高光谱图像超分。该方法通过入翻转、旋转、缩放等数据增强技术 (Timofte等, 2016) 进行数据扩充。以上两种基于CNN的光谱超分方法, 分别通过均通过尺寸为 36×36 (Galliani等, 2017) 和 64×64 (Can和Timofte, 2018) 的图像块构建光谱映射关系, 巨大的索引空间需要大量训练样本以防止过拟合。为了有效减少索引空间, Han等 (2022) 以光谱域作为索引空间构建非线性光谱映射关系, 提出了基于BPNN的光谱超分方法。有鉴于难以在全空间中建立一致的多光谱到高光谱图像的光谱映射关系, 该方法引入多路神经网络的概念, 从而实现在不同子空间上分别建立相应的非线性光谱映射关系。在训练阶段, 利用无监督聚类方法, 按光谱相关性将多光谱图像分为若干类别, 通过多路BPNN分别利用通用图像数据库所提供的分类后多光谱图像与相应高光谱图像组成的光谱对, 建立针对不同类别的非线性光谱映射关系; 在光谱超分阶段, 利用关联聚类方法对给定的多光谱图像进行监督分类, 将其分类为训练阶段确定的类别, 并使用已训练的相应类别BPNN由给定的多光谱图像恢复重建出最终的高光谱图像。随着

深度卷积神经网络的发展, Shi等(2018)研发了一种基于深度残差块与密集连接结构的光谱超分方法。相似地, Martínez等(2020)建立了基于U-net预训练CNN的非线性光谱映射模型。为了进一步提高重建性能, Fu等(2018, 2022)提出了一种具有光谱响应函数选择层的CNN方法, 该方法可以在非负稀疏约束下从网络权重中自动确定最优光谱响应函数。通过结合分解网络和自监督网络, Hang等(2020)提出了一种先验驱动的光谱超分方法。基于相邻光谱波段一般具有较高相关性这一先验信息, 该方法设计了一个分解网络将光谱波段分为若干组, 并设计相应的残差网络分别重构所属光谱波段的光谱与空间信息; 基于RGB图像可以视为高光谱图像的三维投影这一先验信息, 该方法还设计了自监督网络对分解网络的重建结果进行微调。为了同时挖掘空间和光谱信息, Zheng等(2022)提出了一种空间—光谱残差注意网络由多光谱图像重建高光谱图像。首先, 该方法在特征提取部分利用空间—光谱残差注意网络通过两支路结构并行挖掘多光谱图像的空间与光谱特征; 其次, 在非线性映射部分, 建立多光谱特征到高光谱特征的映射模型; 最后, 利用二维卷积重建高分高光谱图像。同时, 该方法利用相邻光谱关注模块保持重建高分高光谱图像相邻光谱波段的相关性。不同于侧重追求更深或更广网络结构的光谱超分方法, Li等(2022)提出了一种使用双路径架构的混合注意力CNN网络。该网络在两侧叠加若干具有波段注意力模块的二维残差组和一维残差组, 通过并行池化架构分别提取波段统计信息和光谱特征; 同时, 该方法设计了RGB与HSI图像空间结构信息一致性模块, 并将光谱梯度约束和平均相对误差作为损失函数, 进一步抑制了空间与光谱失真。Dian等(2024)提出了一种基于交叉融合模型引导网络从RGB图像重建高光谱图像。基于成像模型, 该方法将光谱超分分解为高光谱先验学习模块和成像模型引导模块; 高光谱先验学习模块利用两个子网络分别学习高光谱图像的空间和光谱先验, 并采用交叉融合策略建立两个子网络之间的连接; 成像模型引导模块自适应优化上述空间与光谱先验。

不同于上述基于数据驱动的光谱超分方法, He等(2022)将数据驱动方法与优化算法相结合, 提出了一种基于光谱响应函数引导的CNN方法来

提高多光谱图像的光谱分辨率。该方法通过引入通道注意力模块、空间—光谱网络、特征提取网络, 利用物理信息和光谱响应函数对光谱波段分组, 进一步提升多光谱图像的光谱分辨率。为了进一步降低数据驱动方法对训练图像对数量的需求, Chen等(2022a)研发了一种半监督光谱退化约束网络用于高光谱图像重建。采用多光谱—高光谱图像对和大量多光谱图像半监督训练模式, 该网络由编码器子网络和解码器子网络串联组成。其中, 编码器子网络用于实现从多光谱图像重建高光谱图像, 解码器子网络用于实现从高光谱到多光谱图像的光谱退化成像过程。仅利用目标域一幅多光谱—高光谱图像对, 在源域先验知识的指导下, Wei等(2020)所提单样本(one-shot)光谱超分方法就可以重建高光谱图像。该方法引入大量具有不同光谱特征的高光谱图像作为源域, 并由源域先验知识指导目标域图像重建。考虑到目标域与源域中高光谱图像的光谱特征存在较大差异, 该方法引入光谱解混算法用于去除不同光谱特征对目标域光谱重建的干扰。

光谱超分辨率重建的根本在于如何构建由多光谱到高光谱的光谱映射关系, 这一欠定逆问题的解决途径是引进有效的光谱先验信息, 并以此在重建过程中施加各种形式的约束。多光谱与高光谱图像对库从样本学习的侧面描述了两者的潜在关系, 而通用大型光谱库中的典型地物光谱向量则提供了光谱稀疏意义下的精细光谱信息, 因此有望在光谱超分中用作非图像类的光谱先验信息。

5 挑战与展望

尽管现阶段高分高光谱计算成像已经取得了较高的光谱重建精度, 并逐步用于实际应用, 但它仍存在一定的局限性。因此, 未来高分高光谱计算成像的发展趋势可以总结为跨域适应、多库对齐、以及硬件实现等共3个方面。

目前, 基于深度学习的多光谱与高光谱图像融合、以及高光谱图像光谱超分方法具有较高的光谱重建精度, 但需要大量的样本数据和训练时间, 且所训练模型面临较为严重的数据依赖问题。如果训练域与目标域间存在成像环境等所造成的数据分布不一致情况, 则也会影响高分高光谱图像重建精度, 进而影响后续应用。因此, 针对多

光谱与高光谱图像融合、以及高光谱图像光谱超分的域适应问题值得深入研究。

现阶段, 基于单一光谱库的光谱超分方法在高分高光谱图像重建精度和性能上已经取得了较大的提升, 例如 USGS 光谱库、JPL 光谱库 (Sha 等, 2022; Yan 等, 2023; Han 等, 2024)。然而, 考虑到目前许多机构针对不同应用需求构建了诸多应用领域指向的光谱库, 如何充分发挥不同种类光谱库的数据特色、如何进行多库间的数据对齐、以及如何综合利用多库数据进行光谱超分是进一步提升光谱超分性能的关键, 也是未来需要重点研究与关注的问题。

此外, 大部分高精度图像融合与光谱超分方法都需要大量的运算时间, 尤其是基于深度学习的高分高光谱图像重建方法对计算力的要求更高。日益发展的无人机等小型遥感平台也亟需具备硬件支撑的轻小型化高光谱计算成像设备。因此, 高分高光谱图像重建方法的硬件实现, 即研发面向高分高光谱图像重建的低计算复杂度快速方法、研发与 GPU 相结合的高速高分高光谱图像重建方法、研发便携式高分高光谱图像重建设备等, 也是未来高分高光谱计算成像的一个重要发展方向。

6 结 语

本研究针对光学遥感图像融合与光谱超分这两种不同的高分高光谱图像计算成像技术, 构建了基于先验信息的高分高光谱图像计算成像统一框架, 系统梳理了先验信息的可能来源及其作用, 并在此框架下综述了相关方法的发展过程, 系统分析了现有方法的优势与局限性, 明确了相关技术的未来发展方向。主要结论如下:

(1) 针对高分高光谱计算成像存在的问题, 本文构建了一种基于先验信息的高分高光谱图像计算成像统一模型, 该模型将图像融合与光谱超分归结为先验信息不同的高分高光谱图像计算途经; (2) 尽管现阶段从多光谱与高光谱图像融合到高光谱图像光谱超分方法取得了较高的光谱重建精度, 但训练模型固有的数据依赖问题、较长的训练时间、以及如何有效利用多源先验信息是制约计算成像实际应用范围的关键; (3) 未来高分高光谱计算成像的发展趋势可总结为跨域适应、多库对齐、以及轻小型化硬件实现3个方向。

参考文献 (References)

- Aharon M, Elad M and Bruckstein A. 2006. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on Signal Processing*, 54(11): 4311-4322 [DOI: 10.1109/TSP.2006.881199]
- Akhtar N, Shafait F and Mian A. 2014. Sparse spatio-spectral representation for hyperspectral image super-resolution//*Proceedings of the 13th European Conference on Computer Vision*. Zurich: Springer: 63-78 [DOI: 10.1007/978-3-319-10584-0_5]
- Arad B and Ben-Shahar O. 2016. Sparse recovery of hyperspectral signal from natural RGB images//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam: Springer: 19-34 [DOI: 10.1007/978-3-319-46478-7_2]
- Boyd S, Parikh N, Chu E, Peleato B and Eckstein J. 2011. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends® in Machine learning*, 3(1): 1-122 [DOI: 10.1561/22000000016]
- Can Y B and Timofte R. 2018. An efficient CNN for spectral reconstruction from RGB images. *arXiv preprint arXiv: 1804.04647*
- Cao X H, Lian Y S, Wang K X, Ma C and Xu X Q. 2024. Unsupervised hybrid network of transformer and CNN for blind hyperspectral and multispectral image fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5507615 [DOI: 10.1109/TGRS.2024.3359232]
- Chang Y, Bailey D and Le Moan S. 2021. A new coefficient estimation method when using PCA for spectral super-resolution//*Proceedings of 2021 36th International Conference on Image and Vision Computing New Zealand (IVCNZ)*. Tauranga: IEEE: 1-6 [DOI: 10.1109/IVCNZ54163.2021.9653296]
- Chen W J, Zheng X T and Lu X Q. 2022a. Semisupervised spectral degradation constrained network for spectral super-resolution. *IEEE Geoscience and Remote Sensing Letters*, 19: 5506205 [DOI: 10.1109/LGRS.2021.3079961]
- Chen Y, Zeng J S, He W, Zhao X L and Huang T Z. 2022b. Hyperspectral and multispectral image fusion using factor smoothed tensor ring decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5515417 [DOI: 10.1109/TGRS.2021.3114197]
- Clark R N, Swayze G A, Wise R A, Livo K E, Hoefen T M, Kokaly R F and Sutley S J. 2007. USGS Digital Spectral Library Splib06a. SeriesData 231. US Geological Survey [DOI: 10.3133/ds231]
- Dian R, Li S T and Fang L Y. 2019a. Learning a low tensor-train rank representation for hyperspectral image super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*, 30(9): 2672-2683 [DOI: 10.1109/TNNLS.2018.2885616]
- Dian R, Li S T, Fang L Y and Wei Q. 2019b. Multispectral and hyperspectral image fusion with spatial-spectral sparse representation. *Information Fusion*, 49: 262-270 [DOI: 10.1016/j.inffus.2018.11.012]

- Dian R W, Shan T C, He W and Liu H B. 2024. Spectral super-resolution via model-guided cross-fusion network. *IEEE Transactions on Neural Networks and Learning Systems*, 35(7): 10059-10070 [DOI: 10.1109/TNNLS.2023.3238506]
- Dong W S, Fu F Z, Shi G M, Cao X, Wu J J, Li G Y and Li X. 2016. Hyperspectral image super-resolution via non-negative structured sparse representation. *IEEE Transactions on Image Processing*, 25(5): 2337-2352 [DOI: 10.1109/TIP.2016.2542360]
- Ertürk A, Iordache M D and Plaza A. 2016. Sparse unmixing-based change detection for multitemporal hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(2): 708-719 [DOI: 10.1109/JSTARS.2015.2477431]
- Fotiadou K, Tsagkatakis G and Tsakalides P. 2019. Spectral super resolution of hyperspectral images via coupled dictionary learning. *IEEE Transactions on Geoscience and Remote Sensing*, 57(5): 2777-2797 [DOI: 10.1109/TGRS.2018.2877124]
- Fu Y, Zhang T, Zheng Y Q, Zhang D B and Huang H. 2022. Joint camera spectral response selection and hyperspectral image recovery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1): 256-272 [DOI: 10.1109/TPAMI.2020.3009999]
- Fu Y, Zhang T, Zheng Y Q, Zhang D B and Huang H. 2018. Joint camera spectral sensitivity selection and hyperspectral image recovery//*Proceedings of the 15th European Conference on Computer Vision (ECCV)*. Munich: Springer: 812-828 [DOI: 10.1007/978-3-030-01219-9_48]
- Galliani S, Lanaras C, Marmanis D, Baltsavias E and Schindler K. 2017. Learned spectral super-resolution. *arXiv preprint arXiv: 1703.09470*
- Gao L R, Hong D F, Yao J, Zhang B, Gamba P and Chanussot J. 2021. Spectral superresolution of multispectral imagery with joint sparse and low-rank learning. *IEEE Transactions on Geoscience and Remote Sensing*, 59(3): 2269-2280 [DOI: 10.1109/TGRS.2020.3000684]
- Grohnfeldt C, Zhu X X and Bamler R. 2013. Jointly sparse fusion of hyperspectral and multispectral imagery//*Proceedings of 2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS*. Melbourne: IEEE: 4090-4093 [DOI: 10.1109/IGARSS.2013.6723732]
- Han X L, Leng W, Zhang H, Wang W, Xu Q Z and Sun W D. 2024. Spectral library-based spectral super-resolution under incomplete spectral coverage conditions. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5516312 [DOI: 10.1109/TGRS.2024.3392606]
- Han X L, Yu J, Luo J Q and Sun W D. 2019a. Hyperspectral and multispectral image fusion using cluster-based multi-branch BP neural networks. *Remote Sensing*, 11(10): 1173 [DOI: 10.3390/rs11101173]
- Han X L, Yu J, Luo J Q and Sun W D. 2019b. Reconstruction from multispectral to hyperspectral image using spectral library-based dictionary learning. *IEEE Transactions on Geoscience and Remote Sensing*, 57(3): 1325-1335 [DOI: 10.1109/TGRS.2018.2866054]
- Han X L, Yu J and Sun W D. 2017. Hyperspectral image super-resolution based on non-factorization sparse representation and dictionary learning//*Proceedings of 2017 IEEE International Conference on Image Processing (ICIP)*. Beijing: IEEE: 963-966 [DOI: 10.1109/ICIP.2017.8296424]
- Han X L, Yu J, Xue J H and Sun W D. 2020. Hyperspectral and multispectral image fusion using optimized twin dictionaries. *IEEE Transactions on Image Processing*, 29: 4709-4720 [DOI: 10.1109/TIP.2020.2968773]
- Han X L, Zhang H, Xue J H and Sun W D. 2022. A spectral-spatial jointed spectral super-resolution and its application to HJ-1A satellite images. *IEEE Geoscience and Remote Sensing Letters*, 19: 5505905 [DOI: 10.1109/LGRS.2021.3073501]
- Hang R L, Li Z, Liu Q S and Bhattacharyya S S. 2020. Prinnet: a prior driven spectral super-resolution network//*Proceedings of 2020 IEEE International Conference on Multimedia and Expo (ICME)*. London: IEEE: 1-6 [DOI: 10.1109/ICME46284.2020.9102772]
- He J, Li J, Yuan Q Q, Shen H F and Zhang L P. 2022. Spectral response function-guided deep optimization-driven network for spectral super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*, 33(9): 4213-4227 [DOI: 10.1109/TNNLS.2021.3056181]
- He J, Yuan Q Q, Li J, Xiao Y, Liu D H, Shen H F and Zhang L P. 2023. Spectral super-resolution meets deep learning: achievements and challenges. *Information Fusion*, 97: 101812 [DOI: 10.1016/J.INFFUS.2023.101812]
- He M Y, Chang W J and Mei S H. 2013. Advance in feature mining from hyperspectral remote sensing data. *Spacecraft Recovery and Remote Sensing*, 34(1): 1-12. (何明一, 畅文娟, 梅少辉. 2013. 高光谱遥感数据特征挖掘技术研究进展. *航天返回与遥感*, 34(1): 1-12) [DOI: 10.3969/j.issn.1009-8518.2013.01.001]
- Huang B, Song H H, Cui H B, Peng J G and Xu Z B. 2014. Spatial and spectral image fusion using sparse matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3): 1693-1704 [DOI: 10.1109/TGRS.2013.2253612]
- Huang S H and Messinger D W. 2022. An unsupervised Laplacian pyramid network for radiometrically accurate data fusion of hyperspectral and multispectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5527517 [DOI: 10.1109/TGRS.2022.3168511]
- Keshava N and Mustard J F. 2002. Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1): 44-57 [DOI: 10.1109/79.974727]
- Lacerda M P C, Demattê J A M, Sato M V, Fongaro C T, Gallo B C and Souza A B. 2016. Tropical texture determination by proximal sensing using a regional spectral library and its relationship with soil classification. *Remote Sensing*, 8(9): 701 [DOI: 10.3390/rs8090701]
- LeCun Y, Bengio Y and Hinton G. 2015. Deep learning. *Nature*, 521(7553): 436-444 [DOI: 10.1038/nature14539]
- Leng W, Han X L, Deng J W, Zhang H, Li W Q and Sun W D. 2024. Spectral super-resolution by using universal and private jointed spectral library and its applications. *IEEE Transactions on Geosci-*

- ence and Remote Sensing, 62: 5519911 [DOI: 10.1109/TGRS.2024.3405528]
- Li J J, Du S C, Song R, Wu C X, Li Y S and Du Q. 2022. HASIC-Net: hybrid attentional convolutional neural network with structure information consistency for spectral super-resolution of RGB images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5522515 [DOI: 10.1109/TGRS.2022.3142258]
- Li S T, Dian R, Fang L Y and Bioucas-Dias J M. 2018. Fusing hyperspectral and multispectral images via coupled sparse tensor factorization. *IEEE Transactions on Image Processing*, 27(8): 4118-4130 [DOI: 10.1109/TIP.2018.2836307]
- Li S T, Li C Y and Kang X D. 2021. Development status and future prospects of multi-source remote sensing image fusion. *National Remote Sensing Bulletin*, 25(1): 148-166 (李树涛, 李聪好, 康旭东. 2021. 多源遥感图像融合发展现状与未来展望. *遥感学报*, 25(1): 148-166) [DOI: 10.11834/jrs.20210259]
- Martínez E, Castro S, Bacca J and Arguello H. 2020. Efficient transfer learning for spectral image reconstruction from RGB images//*Proceedings of 2020 IEEE Colombian Conference on Applications of Computational Intelligence (IEEE ColCACI 2020)*. Cali: IEEE: 1-6 [DOI: 10.1109/ColCACI50549.2020.9247895]
- Meerdink S K, Hook S J, Roberts D A and Abbott E A. 2019. The ECOSTRESS spectral library version 1.0. *Remote Sensing of Environment*, 230: 111196 [DOI: 10.1016/j.rse.2019.05.015]
- Mei S H, Geng Y H, Hou J H and Du Q. 2022. Learning hyperspectral images from RGB images via a coarse-to-fine CNN. *Science China Information Sciences*, 65(5): 152102 [DOI: 10.1007/s11432-020-3102-9]
- Nezhad Z H, Karami A, Heylen R and Scheunders P. 2016. Fusion of hyperspectral and multispectral images using spectral unmixing and sparse coding. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(6): 2377-2389 [DOI: 10.1109/JSTARS.2016.2528339]
- Nguyen R M H, Prasad D K and Brown M S. 2014. Training-based spectral reconstruction from a single RGB image//*Proceedings of the 13th European Conference on Computer Vision*. Zurich: Springer: 186-201 [DOI: 10.1007/978-3-319-10584-0_13]
- Ouerghemmi W, Gadal S, Mozgeris G, Jonikavičius D and Weber C. 2017. Urban objects classification by spectral library: feasibility and applications//*Proceedings of 2017 Joint Urban Remote Sensing Event (JURSE)*. Dubai: IEEE: 1-4 [DOI: 10.1109/JURSE.2017.7924629]
- Palsson F, Sveinsson J R and Ulfarsson M O. 2017. Multispectral and hyperspectral image fusion using a 3-D-convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 14(5): 639-643 [DOI: 10.1109/LGRS.2017.2668299]
- Ren L F, Gao L R, Wang M H, Sun X and Chanussot J. 2024. HADGSM: a unified nonconvex framework for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5503415 [DOI: 10.1109/TGRS.2023.3349128]
- Rubinstein R, Zibulevsky M and Elad M. 2008. Efficient implementation of the K-SVD algorithm using batch orthogonal matching pursuit. *Computer Science Department, Technion*, 40(8): 1-15
- Salisbury J W, Walter L S, Vergo N and D'Aria D M. 1991. *Infrared (2.1-25 μ m) Spectra of Minerals*. Baltimore: John Hopkins University Press: 267
- Sha L Y, Zhang W J, Ma J H, Li Z, Sun R Q and Qin M. 2022. Full-spectrum spectral super-resolution method based on LSMM//*Proceedings of IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*. Kuala Lumpur: IEEE: 2390-2393 [DOI: 10.1109/IGARSS46834.2022.9883706]
- Shi Z, Chen C, Xiong Z W, Liu D and Wu F. 2018. HSCNN+: advanced CNN-based hyperspectral recovery from RGB images//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Salt Lake City: IEEE: 1052-10528 [DOI: 10.1109/CVPRW.2018.00139]
- Simoes M, Bioucas-Dias J, Almeida L B and Chanussot J. 2015. A convex formulation for hyperspectral image superresolution via subspace-based regularization. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6): 3373-3388 [DOI: 10.1109/TGRS.2014.2375320]
- Sui L, Li L, Li J, Chen N and Jiao Y Q. 2019. Fusion of hyperspectral and multispectral images based on a Bayesian nonparametric approach. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(4): 1205-1218 [DOI: 10.1109/JSTARS.2019.2902847]
- Sun H, Li Q Q, Yu J, Zhou D B, Chen W J, Zheng X T and Lu X Q. 2023. Deep feature reconstruction learning for open-set classification of remote-sensing imagery. *IEEE Geoscience and Remote Sensing Letters*, 20: 6009405 [DOI: 10.1109/LGRS.2023.3295871]
- Tian J, Zhang Y F, Lu Y and Mei S H. 2018. Hyperspectral and multispectral image fusion with dual-source spatial-spectral dictionary//*Proceedings of IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. Valencia: IEEE: 7034-7037 [DOI: 10.1109/IGARSS.2018.8518809]
- Timofte R, De Smet V and Van Gool L. 2014. A+: adjusted anchored neighborhood regression for fast super-resolution//*Proceedings of the 12th Asian Conference on Computer Vision*. Singapore: Springer: 111-126 [DOI: 10.1007/978-3-319-16817-3_8]
- Timofte R, Rothe R and Van Gool L. 2016. Seven ways to improve example-based single image super resolution//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE: 1865-1873 [DOI: 10.1109/CVPR.2016.206]
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing (in Chinese)*, 20(5): 689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. *遥感学报*, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]
- Wang L G, Wang X Y, Vizziello A and Gamba P. 2023. RSAAE: residual self-attention-based autoencoder for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5510614 [DOI: 10.1109/TGRS.2023.3271719]

- Wei Q, Bioucas-Dias J, Dobigeon N and Tournet J Y. 2015. Hyperspectral and multispectral image fusion based on a sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7): 3658-3668 [DOI: 10.1109/TGRS.2014.2381272]
- Wei Q, Dobigeon N and Tournet J Y. 2014. Bayesian fusion of hyperspectral and multispectral images//*Proceedings of 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Florence: IEEE: 3176-3180 [DOI: 10.1109/ICASSP.2014.6854186]
- Wei W, Sun Y X, Zhang L, Nie J T and Zhang Y N. 2020. Boosting one-shot spectral super-resolution using transfer learning. *IEEE Transactions on Computational Imaging*, 6: 1459-1470 [DOI: 10.1109/TCI.2020.3031070]
- Wu J Q, Aeschbacher J and Timofte R. 2017. In defense of shallow learned spectral reconstruction from RGB images//*Proceedings of 2017 IEEE International Conference on Computer Vision Workshops*. Venice: IEEE: 471-479 [DOI: 10.1109/ICCVW.2017.63]
- Xing C D, Cong Y H, Wang Z S and Wang M L. 2022. Fusion of hyperspectral and multispectral images by convolutional sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 19: 6007605 [DOI: 10.1109/LGRS.2022.3155595]
- Xu N, Xiao X Y, Geng X R, You H J and Cao Y G. 2016. Spectral-spatial constrained sparse unmixing of hyperspectral imagery using a hybrid spectral library. *Remote Sensing Letters*, 7(7): 641-650 [DOI: 10.1080/2150704X.2016.1177240]
- Yan H F, Zhao Y Q, Chan J C W and Kong S G. 2023. Spectral super-resolution based on dictionary optimization learning via spectral library. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5400216 [DOI: 10.1109/TGRS.2022.3229439]
- Yang J X, Zhao Y Q and Chan J C W. 2018. Hyperspectral and multispectral image fusion via deep two-branches convolutional neural network. *Remote Sensing*, 10(5): 800 [DOI: 10.3390/rs10050800]
- Yao H X, Chen R Y, Chen W J, Sun H, Xie W and Lu X Q. 2023. Pseudolabel-based unreliable sample learning for semi-supervised hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5527116 [DOI: 10.1109/TGRS.2023.3322558]
- Ye F, Wu Z B, Xu Y, Liu H Y and Wei Z H. 2022. Bayesian hyperspectral image super-resolution in the presence of spectral variability. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5545613 [DOI: 10.1109/TGRS.2022.3228313]
- Yi C, Zhao Y Q and Chan J C W. 2018. Hyperspectral image super-resolution based on spatial and spectral correlation fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 56(7): 4165-4177 [DOI: 10.1109/TGRS.2018.2828042]
- Yi C, Zhao Y Q and Chan J C W. 2019. Spectral super-resolution for multispectral image based on spectral improvement strategy and spatial preservation strategy. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11): 9010-9024 [DOI: 10.1109/TGRS.2019.2924096]
- Yokoya N, Yairi T and Iwasaki A. 2012. Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2): 528-537 [DOI: 10.1109/TGRS.2011.2161320]
- Yuan Y, Wang Q and Li X L. 2020. Hyperspectral and multispectral image fusion using non-convex relaxation low rank and total variation regularization//*Proceedings of IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. Waikoloa: IEEE: 2683-2686 [DOI: 10.1109/IGARSS39084.2020.9323227]
- Zeng J H, Zhou G X, Qiu Y N, Ma Y M and Zhao Q B. 2024. Hyperspectral and multispectral image fusion via Bayesian nonlocal CP factorization. *IEEE Geoscience and Remote Sensing Letters*, 21: 5500705 [DOI: 10.1109/LGRS.2023.3343366]
- Zhang H Z, Yang Y H, Zhang J H and Chen S Y. 2024a. MLKAF-Net: multiscale large kernel attention network for hyperspectral and multispectral image fusion. *IEEE Geoscience and Remote Sensing Letters*, 21: 5000805 [DOI: 10.1109/LGRS.2023.3344595]
- Zhang J, Lu J J, Wang C and Li S T. 2023. Hyperspectral and multispectral image fusion via superpixel-based weighted nuclear norm minimization. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5521612 [DOI: 10.1109/TGRS.2023.3308936]
- Zhang K, Wang M, Yang S Y and Jiao L C. 2018. Spatial-spectral-graph-regularized low-rank tensor decomposition for multispectral and hyperspectral image fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(4): 1030-1040 [DOI: 10.1109/JSTARS.2017.2785411]
- Zhang X D, Gao K, Wang J W, Wang P Y, Hu Z B, Yang Z J, Zhao X B and Li W. 2024b. Target detection adapting to spectral variability in multi-temporal hyperspectral images using implicit contrastive learning. *Remote Sensing*, 16(4): 718 [DOI: 10.3390/rs16040718]
- Zhao T, Zhang Y F, Xue X Q and He M Y. 2016. Hyperspectral and multispectral image fusion using collaborative representation with local adaptive dictionary pair//*Proceedings of 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Beijing: IEEE: 7212-7215 [DOI: 10.1109/IGARSS.2016.7730881]
- Zheng X T, Chen W J and Lu X Q. 2022. Spectral super-resolution of multispectral images using spatial - spectral residual attention network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5404114 [DOI: 10.1109/TGRS.2021.3104476]
- Zhou F, Hang R L, Liu Q S and Yuan X T. 2019. Pyramid fully convolutional network for hyperspectral and multispectral image fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(5): 1549-1558 [DOI: 10.1109/JSTARS.2019.2910990]
- Zhou X Y, Zhang Y, Zhang J P and Shi S Q. 2020. Alternating direction iterative nonnegative matrix factorization unmixing for multispectral and hyperspectral data fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 5223-5232 [DOI: 10.1109/JSTARS.2020.3020586]

Computational imaging of high-spatial-resolution hyperspectral remote sensed images: From fusion to spectral super-resolution

SUN Weidong¹, HAN Xiaolin²

1. Department of Electronic Engineering, Tsinghua University, Beijing 100084, China;

2. School of Mechatronical Engineering, Beijing Institute of Technology, Beijing 100081, China

Abstract: High-spatial-resolution hyperspectral remote sensed images can provide abundant spatial and spectral information at the same time, which is extremely important for practical applications such as precision agriculture, environmental monitoring, target detection and so on, and is one of the long-term goals in the field of remote sensing. Considering that the high-spatial resolution and high-spectral resolution are two imaging indexes mutually restricted from each other, it is still challenging to obtain the high-spatial-resolution hyperspectral images directly using the existing imaging technology, which limits its practical applicability. As one of the important technical means to reconstruct the high-spatial-resolution hyperspectral image, computational imaging can take the low-spatial-resolution hyperspectral image at the same time and over the same scene as a spectral priori, and fuse it with the spatial information provided by the high-spatial-resolution multispectral image based on the imaging model. It can also take the image-pair library or the spectral library as the priori information, and then reconstruct the high-spatial-resolution hyperspectral image by spectral super-resolution through spectral mapping. Here firstly, facing the above different ways of computational imaging for high-spatial-resolution hyperspectral images, a unified computational imaging model for high-spatial-resolution hyperspectral images based on prior information is constructed in this study. Then, according to the different sources of prior information, this paper summarizes the developing process and the related representative methods from the fusion of low-spatial-resolution hyperspectral and high-spatial-resolution multispectral images, to the image-pair learning based spectral super-resolution for high-spatial-resolution hyperspectral images, and to the latest spectral library learning based spectral super-resolution for high-spatial-resolution hyperspectral images. Besides, the basic ideas, advantages and limitations of the existing algorithms are systematically analyzed. And finally, three possible future trends including cross-domain adaptation, multi-library alignment, and hardware implementation are analyzed and discussed in the context of the future research direction of computational imaging for the high-spatial-resolution hyperspectral image. The results show that the computational imaging of high-spatial-resolution hyperspectral remote sensed images is one of the effective ways to break through the physical limitations of the remote sensed imaging system. Incorporating fusion and spectral super-resolution into a unified framework is conducive to systematically combining different sources of prior information, leading to more targeted high-precision and high-stability reconstruction. This study provides a unified framework and technical means for computational imaging of high-spatial-resolution hyperspectral remote sensed images, clarifies the future development direction of remote sensed image fusion and spectral super-resolution, and is expected to furtherly improve the ability of fine structure detection and fine spectral discrimination, thus providing technical support for the subsequent high-precision and high-reliability spectral target detection, object classification and other application tasks.

Key words: remote sensing, high-spatial-resolution hyperspectral image, unified computational imaging model, high-spatial-resolution multispectral image, image-pair library, spectral library

Supported by National Nature Science Foundation of China (No. 41971294, 82471999); Cross-Media Intelligent Technology Project of BNRist of China (No. BNR2019TD01022); Beijing Institute of Technology Research Fund Program for Young Scholars