计算光谱成像：当代概述

JORGE BACCA[1]、EMMANUEL MARTINEZ[1]和 HENRY ARGUELLO*

系统工程系，桑坦德工业大学，布卡拉曼加，哥伦比亚[1]两位作者贡献相同。*通讯作者：*henarfu@uis.edu.co*

arXiv:2303.04848v1 [cs.IT] 8 Mar 2023

编排于*2023*年*3*月*10*日

光谱成像沿空间和光谱坐标采集并处理信息，这些坐标以离散体素量化，可视为一个三维光谱数据立方体。光谱图像（SI）可利用场景中物体、作物和材料的光谱特性对其进行识别。由于大多数光谱光学系统只能采用一维或最多二维传感器，因此难以直接通过现有商用传感器获取三维信息。作为替代方案，计算光谱成像（CSI）应运而生，成为一种传感工具，可利用二维编码投影获取三维数据。随后，必须通过计算恢复过程来重建光谱图像。与传统扫描系统相比，CSI 能够推动快照式光学系统的发展，缩短采集时间并降低计算存储成本。深度学习（DL）的最新进展使数据驱动的计算光谱成像得以设计，从而改进光谱图像重建，甚至能够直接根据二维编码投影执行分类、解混或异常检测等高层次任务。本文总结了计算光谱成像领域的进展，首先介绍光谱图像及其重要性，接着探讨最重要的压缩光谱光学系统。随后将介绍结合深度学习的计算光谱成像，以及将物理光学设计与计算深度学习算法相结合以解决高层次任务的最新进展。 © 2023 Optica 出版集团

https://doi.org/XX

1. 引言

光谱成像采集并处理场景中物体发射或反射的电磁波前，并存储包含空间和光谱信息的三维数据立方体，称为光谱图像（SI）。根据物体的物理和化学成分，每个物体的光谱响应都被认为是独特的，称为光谱特征。因此，光谱图像由多种纯光谱特征混合组成 [1]。因此，光谱图像能够用于查找和识别材料或物体，以及检测物理过程，使其成为遥感 [2, 3], 农业[4], 医学 [5, 6], 食品检测 [7, 8] 和环境监测 [9, 10]等不同领域的重要工具。

扫描式光谱成像采集技术基于摆扫式、推扫式和波长扫描等空谱扫描。摆扫式和推扫式分别逐像素或逐行采集三维光谱图像 [11]。这两种扫描方法广泛应用于机载或星载成像仪，借助传感器运动（在平面内运动或行星自转）进行扫描 [11]。另一方面，波长扫描（二维扫描）使用带通滤光片采集光谱数据 [12]。然而，传统的扫描方法依赖光学系统或目标场景的运动，因此在动态场景中的应用受到限制 [13]。此外，受技术限制，高空间分辨率与高光谱分辨率之间存在众所周知的权衡，因此在技术上难以获取高空谱分辨率图像 [14]。

压缩光谱成像（CSI）是一种替代性传感方案：通过精心设计的光学系统，将所有三维信息编码到低维（二维或一维）投影测量值中 [15]。随后，需要借助计算算法从测量值中恢复三维光谱数据立方体。已有多种折射式压缩光谱成像方案，例如编码孔径快照光谱成像（CASSI） [16], 、其变体彩色编码孔径快照光谱成像（C-CASSI） [17], 、双分散编码孔径快照光谱成像（DD-CASSI） [18]以及3D-CASSI [19]。在这些CSI系统中，数字微镜器件、硅基液晶、可变形反射镜和棱镜等光学编码元件被纳入传感协议，以对入射的光谱光进行编码和色散。这些折射式系统通常体积庞大且不便携，需要在受控环境中才能正常工作。因此，研究人员将定制衍射光学元件（DOE）引入压缩光谱成像，作为一种新型场景编码方式，使其能够

实现便携且更小巧的装置 [20]。基于衍射的压缩光谱成像系统将衍射光学元件（DOE）用作透镜，从而形成一种随光谱波前变化的投影位移空间卷积模型，使得能够通过计算算法对光谱信息进行反卷积 [21–23]。

从计算方法的角度来看，传统的压缩光谱成像重建依赖迭代算法，将光谱场景的先验信息作为正则项加入优化问题中。这些先验包括：在给定正交基上的稀疏性假设 [24], [25], , 例如空间维度上的小波和光谱坐标上的离散余弦变换（DCT） [16], ; 基于线性混合模型的低秩假设 [26, 27], ; 或某些全变分方案 [28–32]。随着深度学习的发展以及光谱成像数据集的激增，已有大量深度神经网络（DNN）被提出用于重建 [33–35], [36, 37]。这些深度神经网络的优点在于，训练完成后，光谱图像可在推理时间内恢复，从而支持实时应用。在这些网络中，黑箱深度神经网络 [33, 34], [35–37] 能够从压缩光谱成像测量中学习非线性映射；基于模型的优化利用从训练数据集中学习到的先验信息 [38],; 基于展开的方案 [39], [40, 41] 则以优化方法为灵感，利用学习到的先验信息训练深度网络；深度图像先验方法则无需训练数据 [42, 43],[44]。此外，考虑到压缩测量保留了数据特征，一些压缩学习方案被用于直接基于压缩光谱成像测量执行分类、解混和异常检测等高级计算任务。

近年来，一些CSI系统的前向传感问题被模拟为完全可微的成像模型，并可与深度计算模型耦合为光学层。CSI中的一些光学元件可以建模为可训练参数，因此可通过端到端方案与深度计算模型的参数联合优化。这种集成使光学系统与计算算法能够协同工作，从而提升任务性能，因为单个损失函数可指导CSI系统和计算算法的训练 [45–48]。

本综述将在第 2 节正式介绍光谱成像，包括传统传感方法、关于光谱图像的一些背景知识以及空谱权衡。在第 4节，将以数学方式描述压缩光谱成像，分别介绍基于编码孔径和光学色散元件的传统快照光谱系统，以及阐述衍射光学元件及其光学系统采集过程数学表述的衍射快照系统。从计算算法的角度，将介绍解析重建，并分析压缩光谱成像中编码元件与深度神经网络的联合设计。此外，第 5节将探讨如何直接从测量值出发，利用计算算法完成分类、光谱解混和异常检测等高层次任务。最后，将在第 7节简要讨论压缩光谱成像的未来。

2. 高光谱图像

光谱图像可表示为一个三阶张量 $\mathcal{F} \in \mathbb{R}^{M\times N\times L}$，其中$(M,N)$ 表示空间分辨率，L 表示光谱波段。根据窄波段的数量，光谱图像通常称为多光谱图像 (MSI)（当 $4 \leq L \leq 6$ 时）或高光谱图像 (HSI)（当$L > 6$ [14]时）。然而，相较于光谱图像可提供的波段数量，每个波段的光谱范围更具代表性。到达

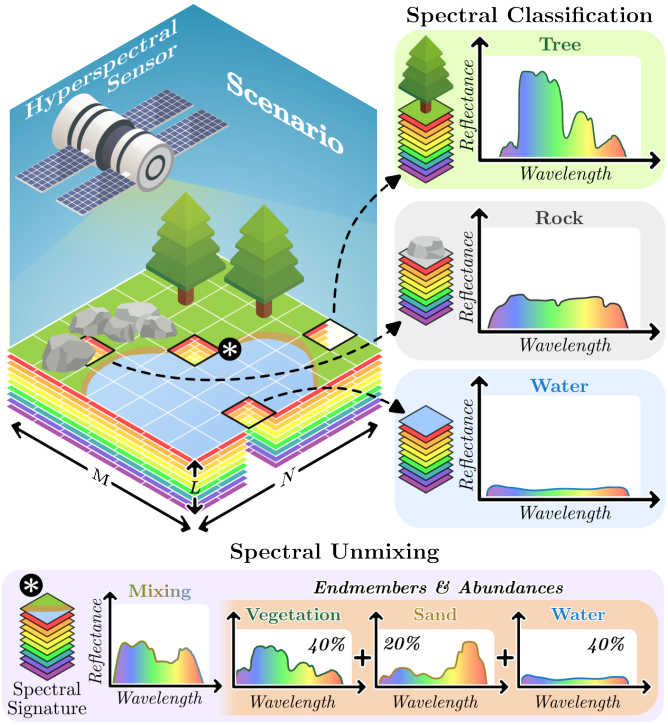


图 1. 光谱图像概述。机载高光谱传感器将电磁辐射捕获为光谱图像。每个光谱特征都能唯一识别其中包含的材料，例如植被、岩石或水。不同材料的混合可通过光谱解混进行分析，其中光谱特征对应于所含材料的线性组合。

地球表面的太阳光几乎全部具有 $300nm$ 至 $2500nm$ [2]之间的光谱响应。因此，光谱成像系统通常感测这一光谱范围。可见光谱 (VIS) 中 $380nm$ 至 $750nm$ 范围内的光谱图像能够感知比人眼更丰富的颜色，从而检测颜色变化。与可见光谱相比，近红外 (NIR) 光谱图像的波长更长，范围为 $780nm$ 至 $2500nm$。与颜色特征相比，近红外范围内感测到的强度更多用于识别材料及其化学成分 [49]。

因此，场景中的每个光谱像素$\mathbf{f}_\ell \in \mathbb{R}^L$ for$\ell = \{1, \cdots MN\}$ 被称为光谱特征，并已被用作执行分类等任务的基本输入向量。分类的目标是根据标注数据集识别每个像素中的对象或材料，或执行解混，即寻找纯像素的丰度，这些纯像素被称为端元，因为某些像素可能是不同端元的混合物，参见图 1中的示例。考虑到光谱图像所提供的信息，人们研究了多种表征模型，以更好地理解光谱图像中包含的信息。下一节将概述线性混合模型，这是一种光谱图像的重要表征，也是解混任务的核心。

A. 线性混合模型

将每个光谱特征堆叠到矩阵中$\mathbf{F} \in \mathbb{R}^{L\times MN}$，用于光谱图像表示的线性混合模型假设，光谱特征可分解为一组端元及其相应的丰度，如图1所示。数学上，

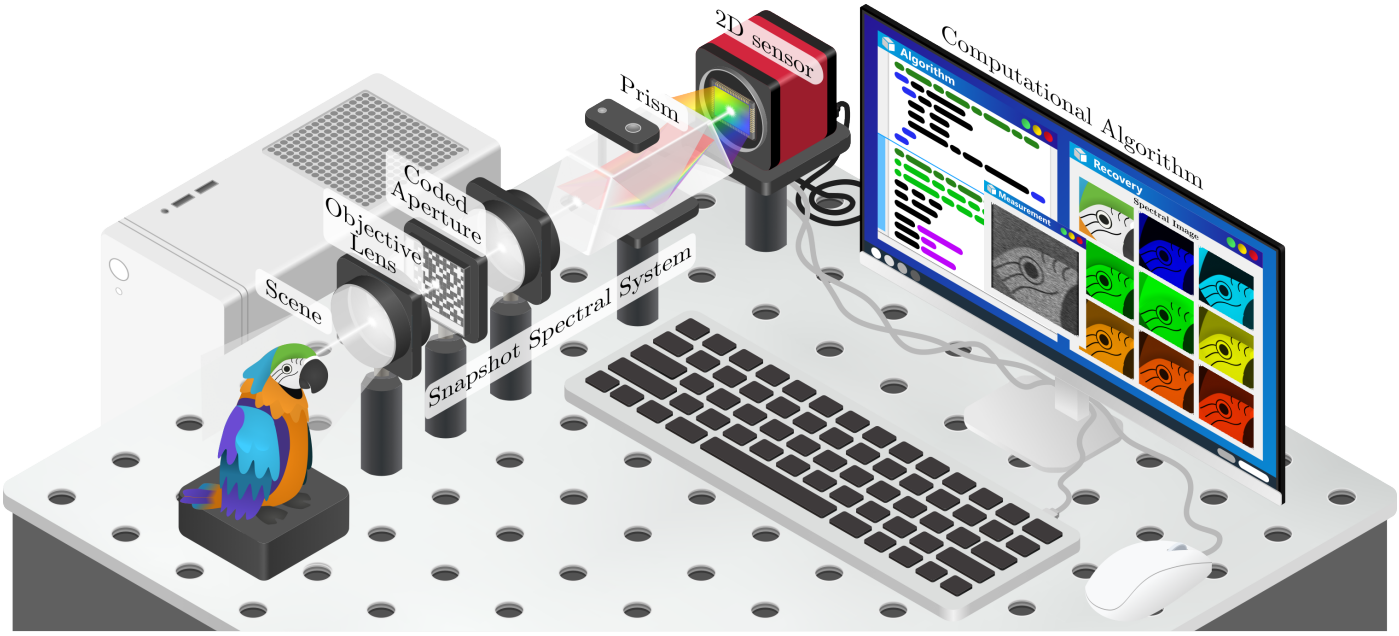


图 2. 压缩光谱成像。光学系统通过专用光学元件对场景进行编码和共享，使二维传感器能够感测空间光谱信息。最后，计算算法处理采集到的测量数据，以恢复原始光谱图像。

秩为r 的光谱场景$\mathbf{F}$ 可表示为

$$\mathbf{F} = \mathbf{EA} + \mathbf{N}, \tag{1}$$

其中 $\mathbf{E} \in \mathbb{R}^{L\times r}$ 是端元矩阵，$\mathbf{A} \in [0,1]^{r\times MN}$ 是每个光谱特征对应的丰度矩阵，最后，$\mathbf{N} \in \mathbb{R}^{L\times MN}$ 是与误差模型相关的误差项。该模型基于这样一个事实：光谱图像具有低维子空间先验，其中 $r << L$ 种材料即可表示整个场景 [42]。该模型已被广泛用于解混任务，即在已知基 $\mathbf{A}$ 的情况下估计丰度 $\mathbf{E}$；此外，它也被用作压缩光谱成像优化问题中的先验信息，正如我们将在第 A节中看到的。值得强调的是，已有研究提出了更忠实的模型，以考虑光谱图像中的可变性 [50] ，或考虑场景中的非线性交互作用 [51], ，详见 [52] 。

3. 基于扫描的光谱成像

商用光谱成像采集技术基于空间光谱扫描，使用能够记录三维信息的一维或二维传感器，因为目前没有三维传感器能够一次拍摄就捕获场景的完整空间光谱信息。下面将详细介绍用于采集光谱图像的三种最常见的非压缩光谱成像技术[53] ，并重点说明高光谱分辨率与高空间分辨率之间的权衡。

摆扫式扫描： 逐像素采集三维数据。点光源通过一组透镜后，棱镜或光栅会对光线进行色散，再由一维传感器阵列感测。由于采用了色散元件，该系统通常能获得较高的光谱分辨率。然而，为了获取高空间分辨率图像，需要通过移动场景或光谱图像系统，对场景进行空间扫描，采集$M \times N$ 次。因此，该系统牺牲了空间分辨率，以便在合理的时间内获取高光谱图像。

推扫式扫描： 逐行扫描场景以获取三维图像。场景的一行通过一组透镜后，经色散并由二维传感器阵列感测。与摆扫式扫描仪相比，推扫式扫描仪的感测系统更为稳健，因为通过光学系统设计，可使一个空间维度M 达到较高分辨率；但要获得高空间分辨率图像，仍需采集N 次。因此，该系统通常获取空间分辨率较低的高光谱图像。

波长扫描： 通过逐个波段扫描场景来采集三维图像。在基于波长扫描的系统中，高空间分辨率场景会通过具有特定光谱响应的光谱滤光片。随后，通过更换滤光片即可采集另一个光谱波段。因此，采集一幅光谱图像需要使用不同的光谱滤光片进行L 次拍摄，成本也会随着滤光片数量的增加而上升。另一种方法是在传感器正前方放置滤光片微阵列，但需要执行去马赛克算法。因此，这类系统通常采集空间分辨率高、光谱分辨率低的多光谱图像。

4. 计算光谱成像

计算光谱成像通过捕获包含整个场景信息的投影测量值，成为一种缓解扫描方法耗时缺陷的替代方案。随后，需要使用恢复算法来获取光谱图像。图2展示了压缩光谱成像的可视化表示。压缩光谱成像有助于开发更快速的采集系统，这些系统能够采集运动中的光谱图像，例如光谱视频 [54]。数学上，编码后的投影测量值 $\mathbf{y} \in \mathbb{R}^m$ 可以线性建模为

$$\mathbf{y} = \mathbf{Hf} + \boldsymbol{\eta}, \tag{2}$$

其中，$\mathbf{f} \in \mathbb{R}^{MNL}$ 表示光谱图像的向量化形式，$\mathbf{H} \in \mathbb{R}^{m\times MNL}$ 表示 CSI 系统的感知矩阵，而$\boldsymbol{\eta} \in \mathbb{R}^m$ 表示系统噪声。

CSI系统	多重-Shot	压缩比	SLM	WDE
编码孔径快照光谱成像 [16, 55]	✓	$\frac{K(N+L-1)}{NL}$	DMD	棱镜/光栅
C-CASSI [17, 56]	✗	$\frac{N+L-1}{NL}$	CCA	棱镜
编码孔径快照光谱成像 + RGB [57]	✓	$\frac{K(N+L-1)}{NL}+\frac{3}{L}$	拜耳滤光片 DMD	棱镜
R-CASSI [58]	✓	K/L	DMD	棱镜
DD-CASSI [18]	✓	K/L	DMD	两个棱镜
SPSI [59]	✓	K/MN	DMD	光谱仪
SSCSI [60]	✗	$1/L$	BCA	光栅
CSI-DMCMD [61]	✓	K/L	CFA	DM
CSI 棱镜 [62]	✗	$\frac{N+L-1}{NL}$	-	棱镜
PMVIS [63]	✗	$\frac{N+L-1}{NL}$	BCA	棱镜
CTIS [64]	✗	$9/L$	-	光栅

表 1. 折射式压缩光谱成像光学系统汇总，其中K 表示快照次数。系统名称是相关论文标题的首字母缩写。数字微镜器件 (DMD)、颜色编码孔径 (CCA)、二值编码孔径 (BCA) 和变形镜 (DM)。

由于$m \ll MNL$，CSI 系统可视为压缩系统。因此，由**y 求得f**的逆问题是一个病态线性问题，因为有许多光谱图像近似值 **f** 都满足方程（2）。根据压缩感知理论，CSI 已证明，只要精心设计感知矩阵**H** ，并在优化算法中利用场景的一些先验信息缩小可行搜索集，就有很大概率重建出光谱图像 [16]。表1和2 列出了一些 CSI 系统，并重点介绍其压缩比和光学元件。下一小节将介绍基于两种主要光学模型的若干 CSI 系统（即感知矩阵**H**的不同结构）：折射式和衍射式。值得指出的是，实际中这两种物理现象都会发生，但在描述感知矩阵时只采用其中一种，而感知矩阵对于重建步骤至关重要。

A. 折射式压缩光谱成像系统

折射式相机在光路中使用稳健的折射透镜。表1总结了一些折射式系统，展示了压缩比、各系统是否支持多次快照，以及两种重要的光学元件：空间光调制器 (SLM) 和波长色散元件 (WDE)。此外，下一节将详细介绍其中一些系统。

编码孔径快照光谱成像(CASSI) [16, 55]是一种压缩光谱成像架构，由折射物镜组成，用于将场景聚焦到二值编码孔径（BCA）上，以阻挡或放行场景中的光线。BCA 由空间光调制器（SLM）实现，例如数字微镜器件。随后，编码后的场景通过 WDE（例如棱镜），产生$L-1$ 像素的水平位移；电荷耦合器件（CCD）则用作焦平面阵列传感器，如图2所示。此外，该系统可通过改变 BCA 的分布采集多个快照，从而提高感知问题的可逆性[16]。因此，感知矩阵被建模为稀疏矩阵**H** $\in \mathbb{R}^{KM(N+L-1)\times MNL}$，其中$K$ 为快照数（有关感知矩阵建模的完整说明，见 [15]）。该系统的硬件压缩率为 $\%_c = K(N+L-1)/NL$。

单像素光谱成像(SPSI) [59] 使用折射透镜将光聚焦到空间光调制器（SLM）上，再由准直透镜将编码后的场景投射到单个空间点。随后，包含 WDE 的摆扫式光谱仪按照编码孔径快照光谱成像架构，通过多个快照采集 L 个波段。请注意，SPSI 系统仅实现空间压缩。因此，感知矩阵被建模为**H** $\in \mathbb{R}^{KL\times MNL}$，其中**H** $= \mathbf{I}_L \otimes \mathbf{C}$；这里$\mathbf{I}_L \in \mathbb{R}^{L\times L}$ 为单位矩阵，**C** $\in \{0,1\}^{K\times NM}$ 为稠密二值矩阵，其每一行表示针对特定拍摄次数的 SLM 图案的向量化结果。总之，该系统的压缩率为 $\%_c = K/MN$。

基于变形镜和彩色马赛克探测器的压缩光谱成像 (CSI-DMCMD) [61]提出了一种紧凑的压缩光谱成像架构，由共焦4f系统、位于中间的变形镜 (DM) 和位于焦平面输出端的彩色滤光片探测器阵列组成。在该架构中，DM 引入受控相位调制，而彩色滤光片则进行空间光谱调制。通过改变 DM 的分布，可获取K 个快照。因此，感知矩阵可建模为稀疏矩阵**H** $\in \mathbb{R}^{MNK\times MNL}$。然后，压缩率为$\%_c K/L$。

在这项研究中，人们提出了多种压缩光谱成像方案，以改进压缩测量的获取。例如，C-CASSI [17] 和 3D-CASSI [65] 采用多种彩色滤光片编码来实现空间光谱调制，从而提升二值编码孔径的性能。另一方面，DD-CASSI [18]采用两个色散元件和一个二值编码孔径，对接收光进行空间光谱编码，同时在传感器上保留场景的空间结构。因此，这些压缩光谱成像变体旨在改善重建问题的条件性，或减少紧凑性、噪声和光通量等光学限制 [58, 62]。

B. 基于衍射的压缩光谱成像系统

衍射式相机包含光学元件，其光传播原理取决于衍射现象，这类元件通常称为衍射光学元件。使用衍射光学元件后，无需采用折射式压缩光谱成像系统中的光学编码元件，因此催生了简单、紧凑且轻便的压缩光谱成像系统设计 [21–23], [71]。因此，衍射式压缩光谱成像系统可建模为：对光谱图像与各波长对应的点扩散函数（PSF）之间的卷积进行光谱积分。从数学上来说，**y** $\in \mathbb{R}^{MN3}$ 表示 RGB测量，而**H** $\in \mathbb{R}^{MN3\times MNL}$ 是一个稀疏矩阵，由传感器的光谱响应与各波长对应的 PSF 卷积矩阵表示的拼接相乘构成。

CSI系统	多重 Shot	压缩比	空间光调制器 + WDE
单个衍射光学元件 [21, 22, 66]	✗	$3/L$	DOE
CSID +CFA [67]	✗	$3/L$	衍射光学元件 + CFA
SCCD [68]	✗	$3/L$	衍射光学元件 + CCA
CSID [23, 69]	✓	K/L	衍射光学元件 + 数字微镜器件
DiffuserCam [70]	✓	$1/L$	扩散器 + CCA

表2. 衍射式压缩光谱成像光学系统汇总。系统名称是相关论文中所用的缩写。衍射光学元件（DOE）、数字微镜器件（DMD）、颜色编码孔径（CCA）和<彩色滤光片阵列>（CFA）。K 表示拍摄次数。

长度。由于 $MN3 < MNL$，该测量问题是不适定的。表 2 列出了一些先进的衍射系统，其中缩写对应于各作者为系统所取的名称或论文名称。接下来将介绍最相关的基于衍射的光学系统。

单个衍射光学元件 [21–23], [71] 用衍射光学元件取代传统 RGB 传感器相机的物镜。这项工作重点在于衍射光学元件高度图轮廓的设计。例如，[21] 提出了一种紧凑型快照式高光谱成像系统，采用衍射旋转，其中衍射光学元件经过设计，可产生一个随波长增加而旋转的目标点扩散函数。 [22] 设计了一种改进的衍射光学元件，并采用光刻技术进行制造，同时设计深度神经网络的参数。然而，尽管衍射光学元件经过了设计，这些系统中的感知矩阵仍会导致严重的病态问题，这是因为缺乏空间编码。

带编码孔径的衍射光学元件 [69] 提出了一种采用衍射透镜（D-CSI）的光学系统，其中编码孔径位于衍射光学元件前方。D-CSI 对场景发射光进行空间编码，随后由衍射光学元件对编码光进行色散和聚焦。对于K次测量和L 个目标波长，感知模型可表示为$\mathbf{H} = \mathbf{PC} \in \mathbb{R}^{KMN\times MNL}$，其中$\mathbf{P} \in \mathbb{R}^{KMN\times MNL}$ 由$M \times M$ 个表示点扩散函数的卷积矩阵组成，而$\mathbf{C} \in [0,1]^{MNL\times MNL}$ 是表示编码矩阵的对角矩阵。压缩率为$\%^{c} = _{KL}$。

带彩色编码孔径的衍射光学元件 [67]通过采用多光谱传感器，将二值编码孔径的用法扩展到彩色滤光探测器。与单个衍射光学元件类似，感知矩阵建模为$\mathbf{H} = \in \mathbb{R}^{KMN\times MNL} \in \mathbb{R}^{KMN\times MNL}$ $\mathbf{DP}$，其中$\mathbf{D}$ 表示多光谱传感器的响应。另一方面， [68] 提出将彩色编码孔径移至衍射光学元件与传感器之间。这种感知模型构成了一个空间变异系统，作者据此提出了利用深度学习联合设计衍射光学元件和彩色编码孔径的方法。

5. 计算光谱应用

计算光谱成像相机采集编码投影后，主要任务是使用计算算法恢复光谱图像。近期，一些先进研究表明，执行推理任务并不一定需要获取三维信息。相反，有些方法可以直接应用于测量值。例如，可以执行光谱图像分类 [72–75], 光谱解混 [51, 52, 76] 和异常检测 [77, 78] 等任务。因此，本文将重建过程作为一项计算任务进行介绍，以验证计算光谱成像相机的质量。不过，值得强调的是，在许多先进方法中，重建是执行这些高层次任务的关键步骤。

A. 光谱重建

传统计算算法旨在求解以下优化问题

$$\hat{\mathbf{f}} = \arg\min_{\mathbf{f}} \|\mathbf{y} - \mathbf{Hf}\|_2^2 + \lambda\mathcal{R}(\mathbf{f}), \tag{3}$$

其中， $\mathcal{R}(\cdot)$ 表示利用手工设计先验的正则化项， λ 则是用于控制数据保真度与正则化器之间权衡的正则化参数。通常，恢复算法会引入一个辅助变量，将式（3）拆分为较小的优化问题，分别处理数据保真度项和先验项，遵循分而治之策略。在这种情况下，正则化可以表示为近端算子或投影算子 [29, 31, 32], [79]。半二次分裂（HQS）方法或交替方向乘子法（ADMM） [32]是基于这一策略的两种通用框架。从数学上讲，这些方法会在优化问题式（3）中引入一个辅助变量$\mathbf{v} \in \mathbb{R}^{MNL}$，将其转化为如下约束问题

$$\tilde{\mathbf{f}} = \arg\min_{\mathbf{f}} \|\mathbf{y} - \mathbf{Hf}\|_2^2 + \lambda\mathcal{R}(\mathbf{v}) \ \text{subject to} \ \mathbf{f} - \mathbf{v} = 0. \tag{4}$$

例如，HQS 将优化问题式（4）重新表述为无约束问题

$$\left(\hat{\mathbf{f}}, \hat{\mathbf{v}}\right) = \arg\min_{\mathbf{f},\mathbf{v}} \|\mathbf{y} - \mathbf{Hf}\|_2^2 + \lambda\mathcal{R}(\mathbf{f}) + \frac{\rho}{2}\|\mathbf{f} - \mathbf{v}\|_2^2, \tag{5}$$

其中 ρ 是一个惩罚参数项。式（5）可通过迭代求解 $\mathbf{f}$和 $\mathbf{v}$ 来求解，每次固定一个变量并最小化另一个变量，具体如下

$$\begin{aligned}\mathbf{f}^{k+1} &= \arg\min_{\mathbf{f}} \frac{1}{2}\|\mathbf{y} - \mathbf{Hf}\|_2^2 + \frac{\rho}{2}\|\mathbf{f} - \mathbf{v}^k\|_2^2 \\ &:= \left(\mathbf{H}^T\mathbf{H} + \rho\mathbf{I}\right)^{-1}\left(\mathbf{H}^T\mathbf{y} + \rho\mathbf{v}^k\right),\end{aligned} \tag{6}$$

$$\mathbf{v}^{k+1} = \arg\min_{\mathbf{v}} \lambda\mathcal{R}(\mathbf{v}) + \frac{\rho}{2}\|\mathbf{f}^{k+1} - \mathbf{v}\|_2^2. \tag{7}$$

HQS 因其简洁性而广受欢迎，但参数的选择并非总是简单 [80], 而 ADMM 则成为一种更稳健的收敛方法。ADMM 旨在寻找式（4）增广拉格朗日函数的一个鞍点:

$$\mathcal{L}(\mathbf{f}, \mathbf{v}, \mathbf{u}) = \|\mathbf{y} - \mathbf{Hf}\|_2^2 + \lambda\mathcal{R}(\mathbf{f}) + \frac{\rho}{2}\|\mathbf{f} - \mathbf{v} + \mathbf{u}\|_2^2, \tag{8}$$

可通过求解一系列子问题找到

$$\begin{aligned}\mathbf{f}^{k+1} &= \arg\min_{\mathbf{f}} \frac{1}{2}\|\mathbf{y} - \mathbf{Hf}\|_2^2 + \frac{\rho}{2}\|\mathbf{f} - \mathbf{v}^k + \mathbf{u}^k\|_2^2 \\ &:= \left(\mathbf{H}^T\mathbf{H} + \rho\mathbf{I}\right)^{-1}\left[\mathbf{H}^T\mathbf{y} + \rho\left(\mathbf{v}^k - \mathbf{u}^k\right)\right],\end{aligned} \tag{9}$$

$$\mathbf{v}^{k+1} = \arg\min_{\mathbf{v}} \lambda\mathcal{R}(\mathbf{v}) + \frac{\rho}{2}\|\mathbf{f}^{k+1} - \mathbf{v} + \mathbf{u}^k\|_2^2, \tag{10}$$

$$\mathbf{u}^{k+1} = \mathbf{u}^k + \mathbf{f}^{k+1} - \mathbf{v}^{k+1}. \tag{11}$$

其中$\mathbf{u} \in \mathbb{R}^{MNL}$ 是拉格朗日乘子。方程（10）和方程（7）得到一个近端算子，对于某些正则化项，它有闭式解 [32]。因此，已有多种SI先验。具体而言， [30, 31, 55] 假设光谱图像在空间上平滑，因此具有较低的总变分（TV），即光谱图像在空间差分域中是稀疏的 [56, 59] 利用 ℓ_1-范数在给定的正交归一基（如小波）上探索空间稀疏性，并在DCT域探索光谱稀疏性 [16, 81] 或者 [26, 82]假设光谱图像具有低秩结构，这可由线性混合模型体现。

最强大的深度神经网络已采用深度学习技术，从测量值中恢复光谱图像（U-Net、循环神经网络、生成对抗网络、变换器） [44, 83–86], [37, 40, 58, 87]。这些数据驱动方法利用光谱图像数据集，使恢复任务能够泛化到未见样本。具体而言，给定一个包含$\mathbf{f}_{(i)}\}_{i=1}^{S}$ 的光谱图像数据集 {，该数据集包含S 个样本，以及一个深度神经网络 $\mathcal{N}_{\boldsymbol{\theta}}(\cdot)$，其中 $\boldsymbol{\theta}$为其参数。训练过程包括拟合这些参数，以最小化以下优化问题:

$$\bar{\boldsymbol{\theta}} = \arg\min_{\boldsymbol{\theta}} \frac{1}{S}\sum_{i=1}^{S}\left\|\mathcal{N}_{\boldsymbol{\theta}}(\mathbf{Hf}^{(i)}) - \mathbf{f}^{(i)}\right\|_2^2. \tag{12}$$

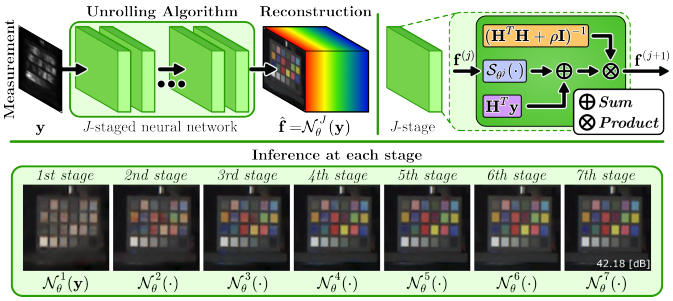


图 3. 光谱图像重建模型。展开算法处理编码投影，直至恢复原始光谱图像；光谱图像重建的灵感源自相关研究成果 [39]。网络的每个阶段都可解释为一次迭代重建。

一些最先进的网络提出，将传统优化方法展开并学习近端算子，从而得到一个可解释深度模型 [39, 48], , 如图3所示。具体而言，该网络由J *stages*$\hat{\mathbf{f}} = \mathcal{N}_{\boldsymbol{\theta}}(\mathbf{y}) = \mathcal{N}_{\boldsymbol{\theta}}^{J}\left(\mathcal{N}^{l}{}_{\boldsymbol{\theta}}^{-1}\left(\cdots\mathcal{N}_{\boldsymbol{\theta}}^{1}\right.\right.$ $\left.\left.(\mathbf{y})\cdots\right)\right)$ 组成，形式如下：

$$\mathcal{N}_{\boldsymbol{\theta}}^{J}(\mathbf{y}) = (\mathbf{H}^{T}\mathbf{H} + \rho\mathbf{I})^{-1}\left(\mathbf{H}^{T}\mathbf{y} + \rho\mathcal{S}_{\boldsymbol{\theta}^{J}}\left(\mathbf{f}^{J-1}\right)\right), \quad \textbf{(13)}$$

其灵感源自一种采用 $\mathcal{S}_{\boldsymbol{\theta}}(\cdot)$ 作为深度光谱先验近端算子的 HQS公式 [32]。图 3展示了基于展开方案的常见表示，其中每个特征（阶段）层表示一次光谱图像估计。

近年来，基于深度图像先验的方法作为一种非数据驱动深度学习方法逐渐兴起，无需使用完整的光谱图像数据集来拟合权重 [42, 43, 88]。通过整合测量值和前向传感模型的深度神经网络，可以捕获光谱图像的低级统计特征。具体而言，网络权重以随机方式初始化，并通过梯度下降算法进行拟合，以确保重建结果符合压缩光谱成像测量值，即最小化 $||\mathbf{H}\mathcal{N}_{\boldsymbol{\theta}}(\mathbf{z}) - \mathbf{y}||_2$其中 $\mathbf{z}$ 可以是随机固定噪声，甚至可以是遵循 Tucker结构 的训练数据 [42, 43]；因此，恢复出的图像在$\mathbf{H}$之前形成，即 $\hat{\mathbf{f}} = \mathcal{N}_{\boldsymbol{\theta}}(\mathbf{z})$。

B. 光谱分类

光谱图像的主要应用之一是识别场景中的材料，从而能够对光谱图像进行逐像素分类。然而，某些压缩光谱成像系统（如编码孔径快照光谱成像和单像素相机）无法保留场景的空间结构或形状。因此，DD-CASSI 和 3D-CASSI 适用于光谱分类，因为探测器中的每个像素仅包含单个光谱像素的投影信息。因此，可以直接使用测量值。例如， [89] 提出了一种基于 DD-CASSI 和贝叶斯框架的自适应光谱图像分类方法。 [75]直接采用无监督子空间聚类技术处理 D-CASSI 测量值，以识别光谱图像中的材料。有趣的是， [74]表明，通过设计二值编码孔径，可以在投影测量值中保留类间和类内特征，从而改善聚类结果，如图4所示。

为了解决非空间保持架构的问题，一些研究采用了转置算子。具体而言，这些方法先提取$\mathbf{f} = \mathbf{H}^{T}\mathbf{y}$形式的特征，以保持图像的维度，然后执行分类任务。 [90] 利用RGB图像的辅助信息设计了快照式偏振光谱成像相机的编码孔径。这种方法能够利用分类准确率。类似地， [72]在SPSI中采用低秩矩阵近似进行特征提取，以最大化关于特征的后验分布，随后可使用最近邻搜索算法。

与其他领域类似，深度学习技术已被定位为直接从压缩域进行光谱分类的最先进方法。例如， [91] 通过三维卷积神经网络（CNNs）和循环神经网络，从测量值中实现高光谱图像的重建与分类，从而加快了基于测量值的采集和分类速度。最新的基于深度学习的光谱图像分类方法探索了对编码孔径值与分类算法进行端到端（E2E）优化，例如下一节将介绍的 [92, 93] 。

C. 光谱解混

光谱解混将光谱图像中的光谱特征分解为一组丰度和端元。随后，每个光谱特征都可以建模为光谱图像中所呈现材料的线性组合。例如， [94] 通过丰度图，基于全变分最小化，利用SPSI测量值重建光谱图像。 [95] 提出使用C-CASSI测量值，在假设稀疏性和已知端元光谱字典的情况下，从测量值中识别端元。类似地， [96]通过CASSI获取压缩测量值，并结合二维波长基和已知的端元光谱库，采用交替方向乘子法策略，为每个像素寻找稀疏向量表示。

其他策略通过测量值实现光谱融合。[82] 提出了一种非迭代的高光谱图像重建方法，对压缩测量值进行融合。具体而言，他们使用了 SPSI 和 3D-CASSI，并假设空谱数据属于低维空间。通过 3D-CASSI 测量值计算丰度，并利用 SPSI 测量值和估计出的丰度估算端元。 [97] 通过线性混合模型融合了从测量值获得的高光谱图像和多光谱图像；该方法在正则化过程中考虑了物理信息中的非负约束和和为一约束，以及总变分。

近期的深度学习方法会考虑丰度和端元的物理约束来学习其表示。在 [42], 给定输入数据后，它们会构建一个深度神经网络 $\mathcal{A}_{\boldsymbol{\theta}} \cdot \quad \mathbb{R}^{M\times N\times L} \to (): ,$ 从输入数 $\mathcal{Z} \in$ $\mathbb{R}^{r\times MN}$ 据生成丰度 $\mathbb{R}^{M\times N\times L}$ $\mathcal{E}_{\mathbf{E}} \cdot \quad \mathbb{R}^{r\times MN} \to \mathbb{R}^{L\times MN}$ 而 $(): ,$ 则是一个利用估计出的丰度执行矩阵运算的深度神经网络，其中

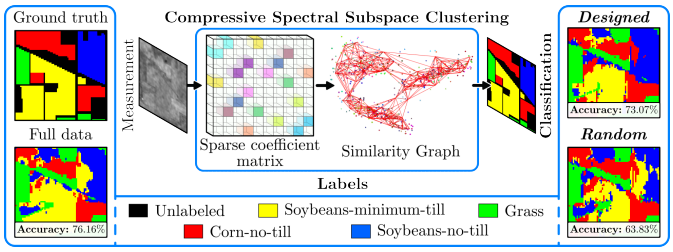


图 4. 光谱图像分类。通过光谱像素聚类算法处理二维编码投影，该算法保留了光谱特征的相似性 [75]。完整数据、设计型和随机光谱图像分类分别展示了直接使用光谱图像，以及使用带有设计型和随机二值编码孔径的压缩测量值所得到的聚类结果。

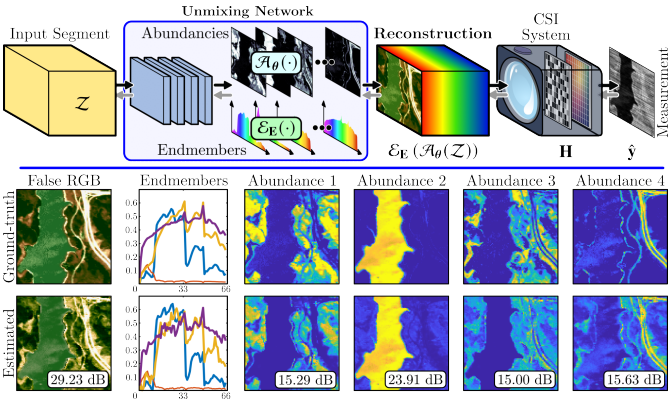


图 5. 基于线性混合模型的光谱图像重建。这种方法的前向模型可根据丰度和端元重建光谱图像。获得的光谱图像将映射到其压缩测量值，从而使其与真实测量值之间的欧氏距离最小化 [42]。网络拟合完成后，某些权重可解释为端元，某些特征则可解释为丰度。

权重可解释为端元。随后，优化问题可表示为

$$\{\hat{\boldsymbol{\theta}}, \hat{\mathcal{Z}}, \hat{\mathbf{E}}\} = \arg\min_{\boldsymbol{\theta},\mathcal{Z},\mathbf{E}} \|\mathbf{y} - \mathbf{H}\mathcal{E}_{\mathbf{E}}\left(\mathcal{A}_{\boldsymbol{\theta}}(\mathcal{Z})\right)\|_2^2 + \mu \left\|\mathbf{1}_r^T \mathcal{A}_{\boldsymbol{\theta}}((\mathcal{Z})) - \mathbf{1}_{MN}\right\|_2^2, \tag{14}$$

其中，第二项对估计的丰度施加物理约束，$\mu \in \mathbb{R}_+$ 为正则化参数，而 $\mathbf{1}_r$，$\mathbf{1}_{MN}$ 分别为长度为r和 MN、元素均为1的向量。最后，重建场景可表示为$\hat{\mathbf{f}} = \mathcal{E}_{\hat{\mathbf{E}}}(\mathcal{A}_{\hat{\theta}}(\hat{\mathcal{Z}}))$，如图5所示，还可通过分析深度神经网络的网络权重和特征来估计丰度和端元。

6. 深度计算光谱成像

多年来，正如本综述所述，压缩光谱成像的发展趋势集中在两个方面：感知和目标任务。然而，近年来得益于CSI系统与深度模型的联合设计，压缩光谱成像的性能得到了提升，超越了传统CSI设计和深度重建方法各自独立使用时的表现。这种方法被称为端到端，因为它从感知到任务整体考虑问题。具体而言，这种数据驱动方法将计算光谱成像成像模型模拟为一个全可微前向模型，其中一些光学元件可被视为可训练参数，记作 $\boldsymbol{\Phi}$。感知模型通常实现为一个自定义层（$\mathbf{H}_{\boldsymbol{\Phi}}\mathbf{f}$），并与深度神经网络耦合，如图6所示。从这个意义上说，CSI被建模为该模型的第一层。在一个训练步骤中，可利用训练数据集通过反向传播算法，以端到端方式设置参数（光学元件和网络权重）。可采用最优光学参数制造CSI系统，以获得原始测量值；这些测量值可直接作为其余深度神经网络的输入，用于执行所需任务。

给定一组带标签的光谱图像，深度压缩光谱成像在数学上可表述为以下优化问题的解

$$\begin{aligned} \{\hat{\boldsymbol{\Phi}}, \hat{\theta}\} &= \arg\min_{\boldsymbol{\Phi},\boldsymbol{\theta}} \mathcal{L}(\boldsymbol{\Phi}, \boldsymbol{\theta}) \\ \mathcal{L}(\boldsymbol{\Phi}, \boldsymbol{\theta}) &:= \sum_{i=1}^{S} \mathcal{L}_{task}\left(\mathcal{N}_{\boldsymbol{\theta}}\left(\mathbf{H}_{\boldsymbol{\Phi}}\mathbf{f}^{(i)}\right), \mathbf{d}^{(i)}\right) + \lambda\mathcal{R}(\boldsymbol{\Phi}), \end{aligned} \tag{15}$$

其中 $\{\mathbf{f}^{(i)}, \mathbf{d}^{(i)}\}_{i=1}^{S}$ 表示数据集，其中$\mathbf{d}^{(i)}$ 是第i 个样本的目标输出任务，而 $\mathcal{N}_{\boldsymbol{\theta}}(\cdot)$ 表示以$\boldsymbol{\theta}$为参数的深度神经网络。端到端方案中的正则化 $\mathcal{R}(\boldsymbol{\Phi})$与传统深度神经网络训练或重建中的正则化作用不同，其目标是促使光学元件收敛到预期行为，以解决光学元件的一些物理限制。在优化问题中使用正则化项，可通过链式法则计算光学元件的梯度，如下所示：

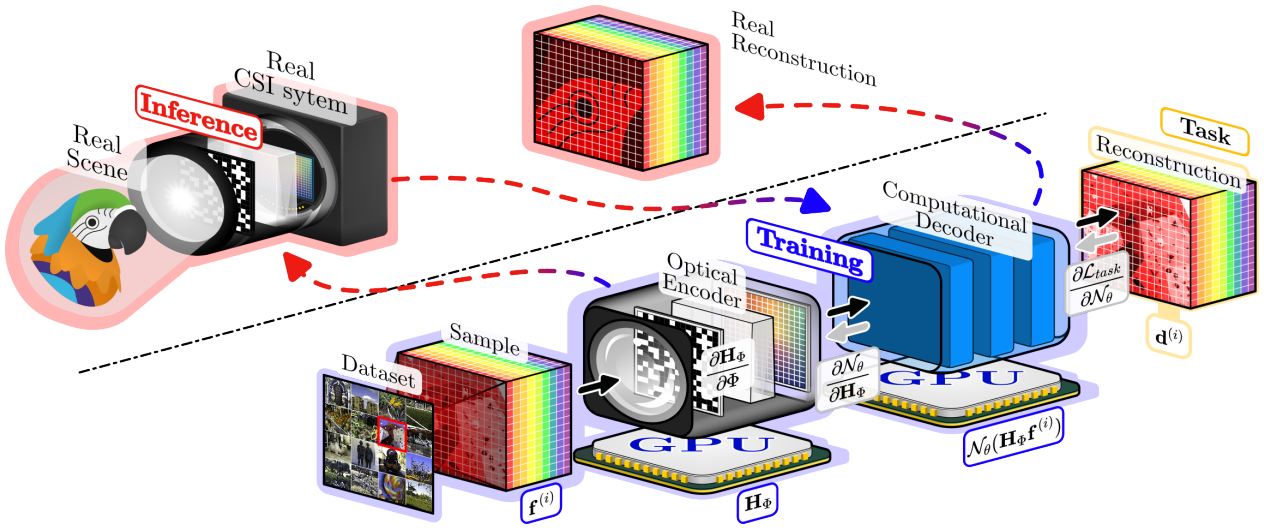


图 6. 端到端深度光学。训练步骤：分别将CSI系统和计算算法建模为带有光学编码器和计算编码器的全可微前向模型。利用给定数据集针对目标任务（重建或分类）训练该模型，并通过梯度下降优化参数，直至收敛。推理步骤：在真实搭建实验室中构建光学编码器，并通过计算解码器完成目标任务。

$$\frac{\partial \mathcal{L}}{\partial \mathbf{\Phi}} = \frac{\partial \mathcal{L}_{task}}{\partial \mathcal{N}_{\theta}} \cdot \left(\frac{\partial \mathcal{N}_{\theta}}{\partial \mathbf{H}_{\mathbf{\Phi}}} \right) \cdot \left(\frac{\partial \mathbf{H}_{\mathbf{\Phi}}}{\partial \mathbf{\Phi}} \right) + \lambda \frac{\partial \mathcal{R}}{\partial \mathbf{\Phi}}, \quad (16)$$

其中，光学元件的设计受深度神经网络参数的影响，因为正则化项 [45]。

例如，在 [98], 作者提出在编码孔径快照光谱成像系统中学习二值编码孔径，并将其与一种基于卷积神经网络的新型恢复网络联合起来，其中权重（二值编码孔径）被建模为完全可微的分段阈值函数。 [46] 提出了一个通用框架，通过正则化器处理编码孔径快照光谱成像系统中的若干重要概念，如透射率、拍摄次数和编码孔径的二进制值。 [46] 表明，通过组合一些正则化项，可以提高重建性能。 [68] 通过深度学习技术联合设计衍射光学元件和彩色编码孔径，并制作原型进行实验，以验证该光学系统；该系统可恢复 420–660 nm 范围内的 49 个光谱波段。

对于光谱图像分类， [92] 通过编码孔径快照光谱成像系统联合设计了二值编码孔径，并采用三维卷积神经网络；该网络采用基于图像块的结构，用于处理二值编码孔径值和三维卷积神经网络参数。 [93] 在塔希提酸橙分级案例研究中采用了类似的端到端方法，并且该方法可扩展至其他农业材料。

7. 结论、挑战与未来工作

本文概述了计算光谱成像，从其研究动机到利用深度学习执行的高层次任务。压缩光谱成像（CSI）表明，基于光学编码元件的专用光学系统能够以比传统光谱传感更短的时间采集光谱图像（SI）。虽然压缩光谱成像可作为一种实用的光谱采集方案，但要使其适用于商业应用，仍需解决两个关键问题。（1）从光学角度来看，需要紧凑、快速的捕获系统。在这方面，衍射光学似乎是开发紧凑设计的一种替代方案，可更便捷地捕获光谱信息。然而，这些系统缺乏合适的编码模式，因此重建的重担便完全落在重建算法上。因此，开发一种能够实现适当编码的紧凑系统，是一项短期挑战。（2）由于压缩光谱成像的本质并非直接采集数据，因此需要求解一个病态逆问题，并提供可靠的联合传感与计算算法。许多实验设计所展示的结果仍局限于在特定理想照明条件下研究的数据库；在此过程中，准确的建模和校准发挥着至关重要的作用。就此而言，目前所有恢复方法都聚焦于深度模型；这些算法高度依赖数据和光学系统，难以扩展，且缺乏可解释性。

另一方面，基于深度学习的光学元件与计算算法联合设计将探索不同的光学设计方案。例如， [48] 开展了多光谱与高光谱图像融合研究，其中利用展开网络对多光谱和高光谱图像编码进行联合优化，超越了先进方法。然而，深度压缩光谱成像仍存在一些开放性问题。例如，尚未探索最优训练方案。此外，在这一新的CSI系统中，尚未对数据依赖性进行正式评估。尽管所有系统都声称能够获得更好的重建效果，但对于计算任务而言，系统与深度神经网络的联合训练尚未得到更深入的研究。换言之，当前系统中哪一种能够提供更好的光谱分类或实现光谱解混，仍属未知。此外，在这种联合设计中，一些制造误差可能导致设计阶段未考虑到的失效。面向光传输的鲁棒端到端训练机制将是未来需要解决的问题。尽管存在这些开放性问题，但在不太遥远的未来，预计CSI系统将主要应用于存储和传输时间至关重要的专业场景，例如空间卫星或农村监测系统。

资助。 本研究由哥伦比亚特许权使用费总局通过资助项目 BPIN 2020000100415 提供支持，UIS 编号为 8933。

利益披露。 作者声明不存在任何利益冲突。

参考文献

1. C. Quintano, A. Fernández-Manso, Y. E. Shimabukuro, and G. Pereira, 《光谱解混》, 《国际遥感杂志》**33**, 5307–5340（2012）。2. G. A. Shaw and H. K. Burke, 《用于遥感的光谱成像》, 林肯实验室期刊**14**, 3–28（2003）。3. J. B. Adams and A. R. Gillespie, 《利用光谱图像进行景观遥感：一种物理建模方法》 （剑桥大学出版社，2006）。4. H. Ge, M. Lv, X. Lu, Y. Jiang, G. Wu, G. Li, L. Li, Z. Li, and Y. Zhang, 《太赫兹光谱成像在农产品检测中的应用》, 载于《光子学》, （MDPI股份公司，2021），11，页518。5. R. M. Levenson and J. R. Mansfield, 《生物学和医学中的多光谱成像：生命切片》, 《细胞计量学A辑：国际分析细胞学学会期刊》**69**, 748–758（2006）。6. E. Aloupogianni, M. Ishikawa, T. Ichimura, A. Sasaki, N. Kobayashi, and T. Obi, 《用于色素性皮肤病变大体病理学的高光谱成像系统设计》, 载于 *2021*年第*43*届 *IEEE*医学与生物学工程学会国际年会（*EMBC*）, （IEEE，2021），第3605–3608页。7. J. Qin, K. Chao, M. S. Kim, R. Lu, and T. F. Burks, 《用于评估食品安全和质量的高光谱与多光谱成像》, 《食品工程杂志》**118**, 157–171（2013）。8. K. Wang, H. Pu, and D.-W. Sun, 《用于快速检测微生物的新兴光谱技术与光谱成像技术：综述》, 《综合食品科学与食品安全评论》**17**, 256–273（2018）。9. M. De Biasio, T. Arnold, R. Leitner, G. McGunnigle, and R. Meester, 《利用多光谱成像进行基于无人机的环境监测》, 载于《机载情报、监视与侦察（*ISR*）系统及应用 *VII*》, 第7668卷（国际光学工程学会，2010）, 第331–337页。10. M. B. Stuart, A. J. McGonigle, and J. R. Willmott, 《环境监测中的高光谱成像：紧凑型现场部署系统的最新进展与技术发展综述》, 《传感器》**19**, 3071（2019）。11. J. E. Fowler, 《用于高光谱遥感成像的压缩推扫式与摆扫式成像》, 载于 *2014*年*IEEE*国际图像处理会议（*ICIP*）, （IEEE，2014），第684–688页。12. T. Zimmermann, J. Rietdorf, and R. Pepperkok, 《光谱成像及其在活细胞显微镜成像中的应用》, 《欧洲生化学会联合会快报》**546**, 87–92（2003）。13. R. A. Borsoi, T. Imbiriba, J. C. M. Bermudez, C. Richard, J. Chanussot, L. Drumetz, J.-Y. Tourneret, A. Zare, and C. Jutten, 《高光谱数据解混中的光谱变异性：全面综述》, 《IEEE地球科学与遥感杂志》**9**, 223–270（2021）。14. S. Chaudhuri and K. Kotwal, 《高光谱图像融合》 （Springer，2013）。15. X. Yuan, D. J. Brady, and A. K. Katsaggelos, 《快照压缩成像：理论、算法与应用》, 《IEEE信号处理杂志》**38**, 65–88（2021）。16. G. R. Arce, D. J. Brady, L. Carin, H. Arguello, and D. S. Kittle, 《压缩编码孔径光谱成像：导论》, 《IEEE信号处理杂志》**31**, 105–115（2013）。17. H. Arguello and G. R. Arce, 《通过集中测度进行压缩光谱成像的彩色编码孔径设计》, 《IEEE 图像处理汇刊》**23**, 1896–1908（2014）。

18. M. E. Gehm, R. John, D. J. Brady, R. M. Willett, and T. J. Schulz, 《采用双分散器架构的单次曝光压缩光谱成像》, 《光学快报》**15**, 14013–14027（2007）。19. C. V. Correa, C. A. Hinojosa, G. R. Arce, and H. Arguello Sr, 《多快照彩色压缩光谱成像仪》, 《光学工程》**56**, 041309（2016）。20. D. W. Wilson, P. D. Maker, R. E. Muller, P. Mouroulis, M. R. Descour, C. E. Volin, and E. L. Dereniak, 《用于光谱成像的衍射光学元件》, 载于 《衍射光学与微光学》, （Optica 出版集团, 2000）, 页DWB1。21. D. S. Jeon, S.-H. Baek, S. Yi, Q. Fu, X. Dun, W. Heidrich, and M. H. Kim, 《利用衍射旋转实现紧凑型快照高光谱成像》, 《ACM 图形学汇刊》（TOG）（2019）。22. X. Dun, H. Ikoma, G. Wetzstein, Z. Wang, X. Cheng, and Y. Peng, 《用于全光谱计算成像的学习型旋转对称衍射消色差透镜》, 《Optica》**7**, 913–922（2020）。23. H. Hu, H. Zhou, Z. Xu, Q. Li, H. Feng, Y. Chen, T. Jiang, and W. Xu, 《基于衍射光学元件的实用快照高光谱成像》, 《光学与激光工程》**156**, 107098（2022）。24. M. F. Duarte and R. G. Baraniuk, 《光谱压缩感知》, 《应用与计算调和分析》**35**, 111–129（2013）。25. P. Yang, L. Kong, X.-Y. Liu, X. Yuan, and G. Chen, 《剪切波增强的快照压缩成像》, 《IEEE 图像处理汇刊》**29**, 6466–6481（2020）。26. T. Gelvez, H. Rueda, and H. Arguello, 《用于压缩高光谱成像的联合稀疏与低秩恢复算法》, 《应用光学》**56**, 6785–6795（2017）。27. T. Gelvez-Barrera, H. Arguello, and A. Foi, 《用于高光谱—多光谱图像融合的联合非局部、光谱及相似性低秩先验》, 《IEEE 地球科学与遥感汇刊》**60**, 1–12（2022）。28. T. Gelvez and H. Arguello, 《利用总变分和低秩正则化从压缩投影中进行光谱图像融合》, 载于 *2018*年第*26*届欧洲信号处理会议（*EUSIPCO*）, （IEEE, 2018）, 第1985–1989页。29. A. Beck and M. Teboulle, 《用于线性逆问题的快速迭代收缩阈值算法》, 《SIAM成像科学杂志》**2**, 183–202（2009）。30. X. Yuan, 《基于广义交替投影的压缩感知总变分最小化》, 载于 *2016*年*IEEE*国际图像处理会议（*ICIP*）, （IEEE, 2016）, 第2539–2543页。31. J. M. Bioucas-Dias and M. A. Figueiredo, 《新思路：用于图像复原的两步迭代收缩/阈值算法》, 《IEEE图像处理汇刊》**16**, 2992–3004（2007）。32. S. Boyd, N. Parikh, E. Chu, B. Peleato, J. Eckstein 等, 《通过交替方向乘子法实现分布式优化与统计学习》, 《机器学习基础与趋势》**3**, 1–122（2011）。33. O. Ronneberger, P. Fischer, and T. Brox, 《U-Net：用于生物医学图像分割的卷积网络》, 载于 国际医学图像计算与计算机辅助手术会议, （Springer, 2015）, 第234–241页。34. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, 《生成对抗网络》, 《ACM通讯》**63**, 139–144（2020）。35. A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, 《注意力机制就是一切》, 《神经信息处理系统进展》**30** （2017）。36. X. Miao, X. Yuan, Y. Pu, and V. Athitsos, 《L-Net：从快照测量中重建高光谱图像》, 载于 *IEEE/CVF*国际计算机视觉会议论文集, （2019）, 第4059–4069页。37. L. Wang, Z. Wu, Y. Zhong, and X. Yuan, 《利用卷积与上下文变换器进行快照光谱压缩成像重建》, 《光子学研究》**10**, 1848–1858（2022）。38. I. Choi, D. S. Jeon, G. Nam, D. Gutierrez, and M. H. Kim, 《利用光谱先验实现高质量高光谱重建》, 《ACM 图形学汇刊》（TOG）**36**, 1–13（2017）。39. B. Monroy, J. Bacca, and H. Arguello, 《Jr2Net：用于压缩光谱成像的联合非线性表示与恢复网络》, 应用光学**61**, 7757–7766 (2022). 40. L. Wang, C. Sun, M. Zhang, Y. Fu, and H. Huang, “Dnu：用于计算光谱成像的深度非局部展开,” 载于 *IEEE/CVF*计算机视觉与模式识别会议论文集,(2020), pp. 1661–1671. 41. S. Zhou, T. Xu, S. Dong, and J. Li, “Rdfnet：用于光谱快照压缩成像的区域动态FISTA网络,” 《IEEE 计算成像汇刊》(2023). 42. T. Gelvez, J. Bacca, and H. Arguello, “受线性混合模型启发、用于压缩光谱图像恢复的可解释深度图像先验方法,” 载于*2021*年*IEEE*国际图像处理会议 *(ICIP)*,(IEEE, 2021), pp. 1934–1938. 43. J. Bacca, Y. Fonseca, and H. Arguello, “利用深度先验和低秩张量表示进行压缩光谱图像重建,” 应用光学**60**, 4197–4207 (2021). 44. Z. Meng, Z. Yu, K. Xu, and X. Yuan, “用于光谱快照压缩成像的自监督神经网络,” 载于*IEEE/CVF*国际计算机视觉会议论文集, (2021), pp. 2622–2631. 45. H. Arguello, J. Bacca, H. Kariyawasam, E. Vargas, M. Marquez, R. Het- tiarachchi, H. Garcia, K. Herath, U. Haputhanthri, B. S. Ahluwalia, P. So, D. N. Wadduwage, and C. U. Edussooriya, “计算成像中的深度光学编码设计：一种数据驱动框架,” IEEE Signal Process. Mag.**40**, 75–88 (2023). 46. J. Bacca, T. Gelvez-Barrera, and H. Arguello, “深度编码孔径设计：一种面向计算成像任务的端到端方法,” 《IEEE 计算成像汇刊》**7**, 1148–1160 (2021). 47. L. C. G. Martínez and H. A. Fuentes, “压缩光谱成像中的光学编码设计：从数学优化到深度学习优化,” 纯粹与应用光学 **55**, 19 (2022). 48. R. Jacome, J. Bacca, and H. Arguello, “D2uf：用于压缩光谱图像融合的深度编码孔径设计与展开算法,” IEEE J. Sel. Top. Signal Process. pp. 1–11 (2022). 49. K. Glass, 通过解读航空照片识别自然灾害(爱思唯尔, 2013). 50. A. Zare and K. Ho, “高光谱分析中的端元变异性：处理光谱解混过程中的光谱变异性,” IEEE Signal Process. Mag.**31**, 95–104 (2013). 51. Y. E. Salehani, E. Arabnejad, and S. Gazor, “用于高光谱解混中光谱变异性的增广高斯线性混合模型,” 载于*ICASSP 2021-2021 IEEE*国际声学、语音与信号处理会议 *(ICASSP),* (IEEE, 2021), pp. 1880– 1884. 52. T. Gelvez-Barrera, J. Bacca, and H. Arguello, “Mixture-net：受混合模型启发、用于光谱图像恢复的低秩深度图像先验,” arXiv 预印本 arXiv:2211.02973 (2022). 53. N. Hagen and M. W. Kudenov, “快照光谱成像技术综述,” 《光学工程》**52**, 090901–090901 (2013). 54. K. M. León-López, L. V. G. Carreno, and H. A. Fuentes, “压缩光谱视频感知中的时序彩色编码孔径设计,” 《IEEE 图像处理汇刊》**28**, 253–264 (2018). 55. A. Wagadarikar, R. John, R. Willett, and D. Brady, “用于编码孔径快照光谱成像的单色散器设计,” 应用光学 **47**, B44–B51 (2008). 56. C. V. Correa, H. Arguello, and G. R. Arce, “快照彩色压缩光谱成像仪,” 美国光学学会期刊A辑**32**, 1754–1763 (2015). 57. H. Rueda, D. Lau, and G. R. Arce, “使用RGB图像传感器进行多光谱压缩快照成像,” 《光学快报》**23**, 12207–12221 (2015). 58. Z. Yu, D. Liu, L. Cheng, Z. Meng, Z. Zhao, X. Yuan, and K. Xu, “深度学习赋能的反射式编码孔径快照光谱成像,” 《光学快报》**30**, 46822–46837 (2022). 59. H. Garcia, C. V. Correa, and H. Arguello, “基于单像素测量的多分辨率压缩光谱成像重建,” 《IEEE 图像处理汇刊》 **27**, 6174–6184 (2018). 60. X. Lin, Y. Liu, J. Wu, and Q. Dai, “空谱编码压缩高光谱成像,” 《ACM 图形学汇刊》（TOG）**33**, 1–11 (2014)。

61. M. Marquez, P. Meza, H. Arguello, and E. Vera, “通过变形镜和彩色马赛克探测器实现压缩光谱成像,” 《光学快报》**27**, 17795–17808 (2019). 62. S.-H. Baek, I. Kim, D. Gutierrez, and M. H. Kim, “利用棱镜实现紧凑型单次曝光高光谱成像,” 《ACM 图形学汇刊》（TOG）**36**, 1–12 (2017). 63. X. Cao, H. Du, X. Tong, Q. Dai, and S. Lin, “用于多光谱视频采集的棱镜掩模系统,” IEEE pattern analysis and machine intelligence 汇刊**33**, 2423–2435 (2011). 64. T. Okamoto and I. Yamaguchi, “光谱图像信息的同步采集,” 《光学快报》**16**, 1277–1279 (1991). 65. X. Cao, T. Yue, X. Lin, S. Lin, X. Yuan, Q. Dai, L. Carin, and D. J. Brady, “计算快照式多光谱相机：迈向光谱世界的动态捕捉,” IEEE Signal Process. Mag. **33**, 95–108 (2016). 66. F. S. Oktem, O. F. Kar, C. D. Bezek, and F. Kamalabadi, “利用衍射透镜和学习式重建实现高分辨率多光谱成像,” 《IEEE 计算成像汇刊》**7**, 489–504 (2021). 67. U. Gundogan and F. S. Oktem, “利用衍射透镜和光谱滤光片阵列进行计算光谱成像,” 载于*2021*年*IEEE*国际图像处理会议*(ICIP),* (IEEE, 2021), pp. 2938–2942. 68. H. Arguello, S. Pinilla, Y. Peng, H. Ikoma, J. Bacca, and G. Wetzstein, “移变彩色编码衍射光谱成像系统,” 《Optica》**8**, 1424–1434 (2021). 69. O. F. Kar and F. S. Oktem, “利用衍射透镜进行压缩光谱成像,” Opt. Lett.**44**, 4582–4585 (2019). 70. K. Monakhova, K. Yanny, N. Aggarwal, and L. Waller, “光谱漫射相机：利用光谱滤光片阵列实现无透镜快照式高光谱成像,” 《Optica》**7**, 1298–1307 (2020). 71. S.-H. Baek, H. Ikoma, D. S. Jeon, Y. Li, W. Heidrich, G. Wetzstein, and M. H. Kim, “利用学习式衍射光学实现单次曝光高光谱深度成像,” 载于*IEEE/CVF*国际计算机视觉会议论文集,(2021), pp. 2651–2660. 72. H. Vargas and H. Arguello, “用于压缩光谱图像分类的低秩模型,” 《IEEE 地球科学与遥感汇刊》 **57**, 9888–9899 (2019). 73. J. M. Ramirez and H. Arguello, “基于多传感器压缩测量的光谱图像分类,” 《IEEE 地球科学与遥感汇刊》**58**, 626–636 (2019). 74. C. Hinojosa, J. M. Ramirez, and H. Arguello, “利用超像素和多传感器压缩测量进行空谱分类,” 载于*2019*年*IEEE*国际图像处理会议 *(ICIP),*(IEEE, 2019), pp. 3143–3147. 75. C. Hinojosa, J. Bacca, and H. Arguello, “用于压缩光谱子空间聚类的编码孔径设计,” IEEE J. Sel. Top. Signal Process.**12**, 1589–1600 (2018). 76. Y. Zhou, A. Rangarajan, and P. D. Gader, “高光谱解混中端元变异性的高斯混合模型表示,” 《IEEE 图像处理汇刊》**27**, 2242–2256 (2018). 77. Y. Xu, Z. Wu, J. Chanussot, and Z. Wei, “利用马氏距离正则化张量RPCA从压缩高光谱图像中进行联合重建与异常检测,” 《IEEE 地球科学与遥感汇刊》**56**, 2919–2930 (2018). 78. B. Madathil and S. N. George, “使用*l*_{({1}/{2})}正则化联合稀疏与低秩恢复，同时对欠采样高光谱图像进行重建和异常检测,” 《IEEE 地球科学与遥感汇刊》**57**, 5190–5197 (2019). 79. M. Mel, P. Zanuttigh, and A. Gatto, “高光谱CTIS图像的联合重建与超分辨率,” (2022). 80. Y. Romano, M. Elad, and P. Milanfar, “潜力非凡的小引擎: 去噪正则化（RED）,” SIAM J. on Imaging Sci. **10**, 1804– 1844 (2017). 81. Y. Fu, Y. Zheng, I. Sato, and Y. Sato, “利用空谱相关性进行编码高光谱图像复原,” 载于*IEEE*计算机视觉与模式识别会议论文集, (2016), pp. 3727–3736. 82. J. Bacca, C. V. Correa, and H. Arguello, “基于压缩融合测量的非迭代高光谱图像重建,” IEEE J. IEEE地球观测与遥感精选专题**12**, 1231–1239 (2019). 83. Z. Meng, J. Ma, and X. Yuan, “采用空谱自注意力的端到端低成本压缩光谱成像”，发表于欧洲计算机视觉会议(Springer, 2020), pp. 187–204. 84. Z. Cheng, R. Lu, Z. Wang, H. Zhang, B. Chen, Z. Meng, and X. Yuan, “Birnat：用于视频快照压缩成像的对抗训练双向循环神经网络”，发表于欧洲计算机视觉会议(Springer, 2020), pp. 258–275. 85. J. Eek, “使用生成对抗网络重建高光谱图像”，(2021). 86. Y. Cai, J. Lin, X. Hu, H. Wang, X. Yuan, Y. Zhang, R. Timofte, and L. Van Gool, “用于高效高光谱图像重建的掩码引导逐光谱变换器”，发表于*IEEE/CVF*计算机视觉与模式识别会议论文集(2022), pp. 17502–17511. 87. X. Hu, Y. Cai, J. Lin, H. Wang, X. Yuan, Y. Zhang, R. Timofte, and L. Van Gool, “Hdnet：用于光谱压缩成像的高分辨率双域学习”，发表于*IEEE/CVF*计算机视觉与模式识别会议论文集(2022), pp. 17542–17551. 88. Q. Zhao, X. Zhao, X. Ma, X. Chen, and G. R. Arce, “一种基于稀疏性和深度图像先验的编码孔径快照光谱成像快速交替最小化算法”, arXiv 预印本 arXiv:2206.05647 (2022). 89. M. Dunlop-Gray, P. K. Poon, D. Golish, E. Vera, and M. E. Gehm, “自适应架构用于直接光谱成像分类的实验验证”，《光学快报》**24**, 18307–18321 (2016). 90. C. Hinojosa, K. Sanchez, H. Garcia, and H. Arguello, “C-3spcd：用于单像素测量空谱分类的编码孔径相似性约束设计”，《应用光学》**61**, E21–E32 (2022). 91. D. J. Lee, “用于压缩高光谱成像的深度神经网络”，发表于 成像光谱学*XXIII*：应用、传感器与处理，第 11130 卷 (国际光学工程学会, 2019), pp. 19–37. 92. H. Zhang, X. Ma, X. Zhao, and G. R. Arce, “使用三维编码卷积神经网络进行压缩光谱图像分类”，arXiv 预印本 arXiv:2009.11948 (2020). 93. M. Silva-Maldonado, L. Galvis, and H. Arguello, “端到端压缩光谱分类：一种应用于塔希提酸橙分级的深度学习方法”，发表于智能技术、系统与应用国际会议(Springer, 2022), pp. 44–57. 94. C. Li, T. Sun, K. F. Kelly, and Y. Zhang, “一种用于高光谱数据处理的压缩感知与解混方案”，《IEEE 图像处理汇刊》**21**, 1200–1210 (2011). 95. H. M. Vargas and H. A. Fuentes, “用于光谱图像解混的彩色编码孔径”，发表于遥感图像与信号处理*XXI*第 9643 卷 (国际光学工程学会, 2015), pp. 619–626. 96. A. Ramirez, G. R. Arce, and B. M. Sadler, “从最优编码孔径压缩测量中进行光谱图像解混”，《IEEE 地球科学与遥感汇刊》**53**, 405–415 (2014). 97. E. Vargas, H. Arguello, and J.-Y. Tourneret, “利用光谱解混和丰度图稀疏表示，从压缩测量进行光谱图像融合”，《IEEE 地球科学与遥感汇刊》**57**, 5043–5053 (2019). 98. L. Wang, T. Zhang, Y. Fu, and H. Huang, “Hyperreconnet：用于压缩高光谱成像的联合编码孔径优化与图像重建”，《IEEE 图像处理汇刊》**28**, 2257– 2270 (2018).