

像元映射变分辨率光谱成像重构

肖树林 胡长虹 高路尧 颜克雄 杨春吉 李洪利

Pixel mapping variable-resolution spectral imaging reconstruction

XIAO Shu-lin, HU Chang-hong, GAO Lu-yao, YAN Ke-xiong, YANG Chun-ji, LI Hong-li

引用本文:

肖树林, 胡长虹, 高路尧, 颜克雄, 杨春吉, 李洪利. 像元映射变分辨率光谱成像重构[J]. *中国光学*, 2022, 15(5): 1045–1054.

doi: 10.37188/CO.2022–0108

XIAO Shu-lin, HU Chang-hong, GAO Lu-yao, YAN Ke-xiong, YANG Chun-ji, LI Hong-li. Pixel mapping variable-resolution spectral imaging reconstruction[J]. *Chinese Optics*, 2022, 15(5): 1045-1054. doi: 10.37188/CO.2022-0108

在线阅读 View online: <https://doi.org/10.37188/CO.2022–0108>

您可能感兴趣的其他文章

Articles you may be interested in

光谱成像技术在海域目标探测中的应用

Application of spectral imaging technology in maritime target detection

中国光学 (中英文). 2017, 10(6): 708 <https://doi.org/10.3788/CO.20171006.0708>

超分辨率成像荧光探针材料应用进展

Advances in application of materials of super-resolution imaging fluorescent probe

中国光学 (中英文). 2018, 11(3): 344 <https://doi.org/10.3788/CO.20181103.0344>

LAMOST高分辨率光谱仪研制

Construction of a LAMOST high resolution spectrograph

中国光学 (中英文). 2019, 12(1): 148 <https://doi.org/10.3788/CO.20191201.0148>

深海光学照明与成像系统分析及进展

Analysis and research progress of deep-sea optical illumination and imaging system

中国光学 (中英文). 2018, 11(2): 153 <https://doi.org/10.3788/CO.20181102.0153>

大随机相位误差下条带模式合成孔径激光雷达成像实验

Stripmap mode synthetic aperture ladar imaging under large random phase errors condition

中国光学 (中英文). 2019, 12(1): 130 <https://doi.org/10.3788/CO.20191201.0130>

高分辨率遥感图像SIFT和SURF算法匹配性能研究

Research on matching performance of SIFT and SURF algorithms for high resolution remote sensing image

中国光学 (中英文). 2017, 10(3): 331 <https://doi.org/10.3788/CO.20171003.0331>

文章编号 2097-1842(2022)05-1045-10

像元映射变分辨率光谱成像重构

肖树林^{1,2}, 胡长虹^{1*}, 高路尧^{1,2}, 颜克雄^{1,2}, 杨春吉^{1,2}, 李洪利^{1,2}
(1. 中国科学院长春光学精密机械与物理研究所, 吉林长春 130033;
2. 中国科学院大学, 北京 100049)

摘要:本文讨论了随机滤光片光谱编码-解码的基本原理与重构方法, 利用深度学习欠完备自编码器的自动特征提取机制, 构建了高精度、低延时的像元映射变分辨率光谱成像重构网络, 通过变换像元映射关系完成了 2×2 、 4×4 像元阵列光谱重构网络的并行训练。最后, 利用 512×512 、120 谱段 (430 ~ 670 nm) 的遥感光谱图像对重构网络进行验证, 实现了 2×2 像元阵列/40 谱段重构峰值信噪比达 53 dB、均方误差小于 0.002、重构用时 0.87 s 与 4×4 像元阵列/120 谱段重构峰值信噪比达 64 dB、均方误差小于 10^{-5} 、重构用时 0.52 s 的变分辨率光谱图像重构。实验结果表明像元映射变分辨率光谱成像重构网络具备高精度、低延时的动态变换性能。

关键词: 变分辨率光谱成像; 像元映射; 随机滤光片; 深度学习

中图分类号: O438 文献标志码: A doi: 10.37188/CO.2022-0108

Pixel mapping variable-resolution spectral imaging reconstruction

XIAO Shu-lin^{1,2}, HU Chang-hong^{1*}, GAO Lu-yao^{1,2}, YAN Ke-xiong^{1,2}, YANG Chun-ji^{1,2}, LI Hong-li^{1,2}

(1. *Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;*

2. *University of Chinese Academy of Sciences, Beijing 100049, China)*

* *Corresponding author, E-mail: changhonghu@rocketmail.com*

Abstract: In this paper, the basic principle and reconstruction method of random filter spectral coding-decoding are discussed. According to the automatic feature extraction mechanism of a deep learning undercomplete autoencoder, a pixel mapping variable-resolution spectral imaging reconstruction network with high reconstruction accuracy and low delay is constructed. The parallel training of a 2×2 and 4×4 pixel array spectral reconstruction network is implemented by transforming the pixel mapping relationship. Finally, the network's performance is verified by the remote sensing data with 512×616 with 120 bands spectral images. For a 2×2 pixel array with 40 bands, the reconstruction PSNR is 53 dB, the reconstruction MSE is less than 0.002, and the reconstruction time is 0.85 s. For a 4×4 pixel array with 120 bands, the reconstruction PSNR is

收稿日期: 2022-05-30; 修订日期: 2022-06-22

基金项目: 吉林省与中国科学院科技合作高技术产业化(No. 2020SYHZ0028); (吉林省) 2021 年省预算内基本建设资金(No. 2021C045-3)。

This research is funded by the cooperation project between Jilin Province and Chinese Academy of Sciences (No. 2020SYHZ0028); (Jilin Province) Capital construction funds within the provincial budget in 2021 (No. 2021C045-3).

64 dB, the reconstruction MSE is less than 10^{-5} , and the reconstruction time is 0.5 s. The experimental results show that the pixel mapping variable-resolution spectral imaging reconstruction network has the dynamic transformation performance of high accuracy and low delay.

Key words: variable-resolution spectral imaging; pixel mapping; random filter; deep learning

1 引言

传统光谱成像分辨率的改变通过可调谐滤波器和空间光调制器实现^[1-3], 这些插入器件会导致光谱成像系统结构复杂、体积庞大。此外, 棱镜、光栅、滤波器等窄带分光器件存在光谱能量利用率低、分光谱段少、光谱图像畸变大等问题^[4]。导致这些问题的主要原因是传统光谱成像的光谱均匀采样机制消耗大量探测器面积或扫描时间以满足分辨率要求^[5], 因此为解决传统变分辨率光谱成像存在的问题, 应从光谱的采样机制入手。

随着微纳光学与稀疏信号处理理论的发展, 宽带滤波器(如随机滤光片、量子点阵列^[6]、光子晶体阵列和具有可调谐带隙的纳米线^[7])光谱成像技术逐渐成熟。宽带光谱成像原理是将入射光的光谱信息由一组宽带滤波器进行编码, 在探测器的不同位置探测编码后的光强响应, 然后利用算法重建光谱, 其优点在于每个像素使用少量的滤光结构实现了较多波长光谱信息的复原^[8], 大大提高了光谱的采样效率与光能利用率。其中, 对于具有随机透过率的宽带滤光片(随机滤光片), 可以利用成熟的光学薄膜技术, 设计成透过率误差极小的像元级随机滤光片阵列, 通过与探测器集成, 极大地缩小了光谱成像系统的体积。随机滤光片光谱编解码(编解码)结构最早由韩国光州科学技术院的 J. Oliver 于 2013 年提出^[9], J. Oliver 利用随机滤光片阵列(40×1)对入射光谱进行编码, 由压缩感知算法实现了 7 倍于窄带滤光片分辨率的光谱重构, 但受限于当时薄膜加工水平, 未能将随机滤光片光谱编解码结构应用于光谱成像。2019 年, 清华大学崔开宇、蔡旭升等人设计了规模达 155 216、400 种类型的像元级可重构宽带超表面阵列, 利用压缩感知算法复原了由动态超表面元胞编码后的光谱, 实现最高光谱分辨率可达 0.8 nm 的变分辨率光谱成像^[10], 但由于随机超表面设计独立于重构算法, 在组合像元较少时, 光谱复原精度较低。2021 年, 浙江大

学刘旭、郝翔团队研究了基于深度学习的光谱编解码技术, 并提出了随机滤光片与重构算法协同设计的思想, 大大提高了重构精度、重构速度与抗噪声性能^[11], 同时也为高精度、低时延变分辨率光谱成像的实现提供了新思路。

本文基于随机滤光片光谱编解码框架, 介绍压缩感知和深度学习两种光谱重构算法及其存在的问题, 阐述随机滤光片与重构算法协同优化原理。以像元级随机滤光片阵列光谱成像系统为应用平台, 提出基于协同优化方法的像元映射变分辨率光谱成像重构算法, 通过多分辨率重构网络并行训练, 得到 2×2 阵列、40 谱段与 4×4 阵列、120 谱段的光谱重构网络。最后输入光谱图像验证集进行仿真验证。

2 随机滤光片光谱编解码

自然事物普遍存在稀疏性^[12], 即: 不同表达方式描述一个自然事物所需的符号数量不尽相同, 但总存在最小符号数量的表达方式, 且通常这个表达方式所需的符号数量远小于直观表达的符号数量。随机滤光片光谱编解码即利用光谱的稀疏性, 使用具有随机透过率分布的滤光片对入射光谱进行编码, 将连续的光谱压缩表示成低维的光强向量, 然后通过解码算法还原成人类能够直观理解的光谱向量。理论上光谱能被压缩的最小维度取决于光谱的稀疏性, 但实际工程中由具体需求决定, 通常设计者会通过损失一些重构精度以降低算法复杂度。

根据不同的优化思路, 目前有压缩感知和深度学习这两种重构算法, 其中压缩感知重构算法依靠稀疏降维的方式实现欠定方程求解, 利用稀疏解还原光谱向量; 深度学习重构算法则依靠欠完备自编码器的自动特征提取与数据生成能力实现光谱的重构。这两种算法均存在因物理结构与算法独立设计导致的优化问题, 而随机滤光片与光谱重构算法的协同设计可以很好地解决这个问题。

2.1 压缩感知光谱重构算法

随机滤光片组对原始光谱 $S(\lambda)$ 进行压缩编码, 由光强探测器感应编码后的光强 i , 然后对探测器光电流进行模-数转换(ADC)得到数字量 I , 再将 I 输入数字信号处理器(DSP), 执行压缩感知算法, 完成光谱重构。压缩感知光谱编解码原理如图1(彩图见期刊电子版)所示。

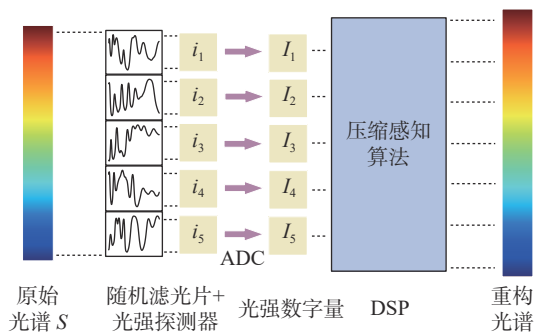


图1 压缩感知光谱编解码原理

Fig. 1 Principle diagram of compressed sensing spectral encoding-decoding

压缩编码后的光强大小为

$$i_n = \int_{\lambda_1}^{\lambda_2} S(\lambda) T_n(\lambda) d\lambda, n = 1 \dots N \quad (1)$$

其中, $S(\lambda)$ 的波长范围为 λ_1 至 λ_2 ($\lambda_1 < \lambda_2$); $T_n(\lambda)$ 表示编号为 n 的随机滤光片的透过率, 一共有 N 种随机滤光片; i_n 为 $S(\lambda)$ 由 $T_n(\lambda)$ 编码后的光强。设 $\mathbf{i} = [i_1, i_2, \dots, i_N]$ 为编码光强向量, 则由数据采集系统得到离散化光强向量 $\mathbf{I} = [I_1, I_2, \dots, I_N]$ 。根据压缩感知理论, 对原始光谱 $S(\lambda)$ 的编解码可以表示成以下两个过程:

A. 稀疏表示:

$$\tilde{S}_K = \Phi p, s.t. \|\tilde{S}_K - \tilde{S}_K\|_2 \leq \xi, \xi \geq 0 \quad (2)$$

B. 信号重构:

$$\hat{p} = \arg \min \|p\|_1, s.t. \|T\Phi\hat{p} - I\|_2 \leq \varepsilon, \varepsilon \geq 0 \quad (3)$$

其中 \tilde{S}_K 为 S 的 K -稀疏逼近, P 为 S 的稀疏表示, ξ 为最大逼近误差, ε 为最大重构误差。首先由字典学习得到 S 的一组 K -稀疏完备正交基 Φ ; 然后利用观测矩阵 T (滤光片透过率矩阵)对 S 进行压缩采样, 再由 l_1 优化算法求解 S 的 K -稀疏表示 \hat{p} , 最后结合稀疏字典实现 S 的重构^[13]。

压缩感知算法为了满足有限等距性质(Restricted Isometry Property, RIP)条件, 要求观测矩

阵 T 与 S 的 K -稀疏完备正交基 Φ 不相关^[14-15]。通常 T 取普适的独立同分布高斯随机矩阵, 导致随机滤光片的设计与加工难度增大^[16]。为了降低薄膜加工难度, 另一种方法是通过随机生成薄膜厚度设计随机滤光片组, 然后根据该组滤光片设计重构算法, 但这种方法得到的滤光片随机特性难以控制, 设计压缩感知算法难度较大, 而基于深度学习的欠完备自编码器因其强大的自动特征提取能力可以较好地适用于这种方法。

2.2 深度学习光谱重构算法

深度学习光谱编码过程与压缩感知光谱编码过程相似, 两者的不同点在于重构算法。深度学习光谱编解码原理如图2(彩图见期刊电子版)所示。

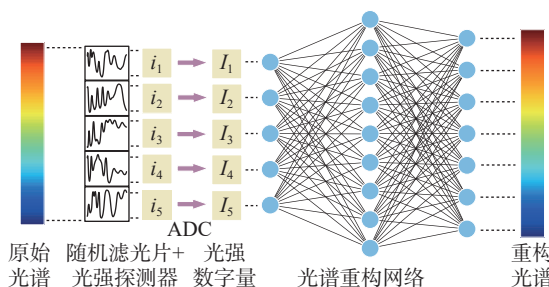


图2 深度学习光谱编解码原理

Fig. 2 Principle diagram of deep learning spectral encoding-decoding

深度学习光谱重构算法的主要目标是训练得到最优的光谱重构网络。将低维离散化光强向量 \mathbf{I} 输入重构网络 REC_ω 得到高维的光谱向量 \hat{S} , 通过优化调整 REC_ω 的参数使得 \hat{S} 不断逼近原始光谱 S 。其优化表达如下:

$$\arg \min_{\omega} \{\|\hat{S} - REC_\omega(I)\|_2 + \lambda R(\omega)\} \quad (4)$$

式中 λ 为正则化因子, ω 为神经网络参数, $\hat{S} = REC_\omega(I)$ 为重构光谱, $R(\omega)$ 为正则项。该式可分为两项: 前一项为重构误差项, 表示 \hat{S} 与 S 的拟合程度; 后一项 $R(\omega)$ 正则项为神经网络参数约束项, 用于防止重构网络过拟合, 一般采用 l_2 正则化约束, 使得 $\|\omega\|_2 \leq C$ ($0 \leq C < \infty$), 两项相加构成损失项, 优化使得损失项值接近零。优化过程如下: 首先是正向传播得到光谱 \hat{S} 的预测值, 然后计算损失值及其对 ω 的梯度, 根据该梯度由反向传播算法更新网络参数 ω 。重复这个过程使得损失值下降接近零, 从而实现网络的最优化。

深度学习光谱编解码实质上是一种欠完备自编码框架。利用随机滤光片实现光谱的物理编码,由光谱重构网络实现光谱的数字解码,通过强制设定编码输出 I 的维度(即随机滤光片的种类 N)重构网络学习光谱数据 S 中的最显著的特征,以得到光谱数据在该编码维度下的最优表示^[17],同时也使得重构网络具备一定的去噪能力。但光谱重构精度严重依赖于随机滤光片透过率分布(由薄膜材料和厚度决定),导致在确定的编码维度下难以实现最优的光谱编解码性能。因而如何将随机滤光片设计与光谱重构网络训练相关联是解决该问题的重点。

2.3 随机滤光片与光谱重构算法协同设计

在基于压缩感知和深度学习的随机滤光片光谱编解码框架中,随机滤光片和重构算法的设计是独立进行的。为了高精度地重构原始光谱,这种独立设计方式往往需要复杂的随机透过率分布与较多的随机滤光片种类,导致随机滤光片设计难度大、光谱采样效率低,无法充分发挥随机滤光片光谱编解码架构的潜力。为此,浙江大学刘旭、郝翔团队提出了一种随机滤光片与光谱重构算法协同设计方法^[11]。

协同设计方法通过将随机滤光片透过率计算与光谱重构网络训练相结合,实现随机滤光片与光谱重构网络的最佳匹配。此外,通过约束随机滤光片的宽带透过率,一方面提高了系统光谱能量利用率,另一方面平衡了像元光能量的接收效率,从而提高了光谱成像的信噪比与扩大了动态范围。随机滤光片与光谱重构网络协同设计如图3(彩图见期刊电子版)所示。

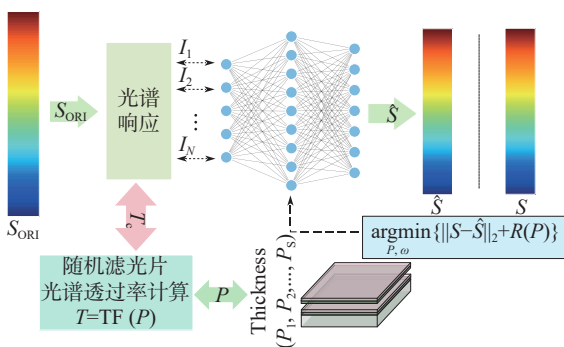


图3 随机滤光片与光谱重构网络协同设计

Fig. 3 Collaborative design of random filter and spectral reconstruction network

协同设计方法关联了光谱重构网络训练与滤

光片透过率计算过程,将随机滤光片的结构参数 $P_{[n]} = [p_{n1}, p_{n2}, \dots, p_{ns}]$, $n = 1, 2, \dots, N$ 作为重构网络的优化参数。计算 $P_{[n]}$ 对应的随机滤光片透率 $T_{[n]}$, 然后由点积运算得到光谱数据 S 对 $T_{[n]}$ 的光谱响应光强 I_n ^[11], 将其输入重构网络计算出光谱 \hat{S} 完成正向传播, 然后根据损失函数(均方误差)计算损失值, 再通过损失值梯度反向传播更新重构网络参数, 重复这个过程直至损失值收敛接近零。其优化表达如下:

$$(\hat{P}, \hat{\omega}) = \arg \min_{P, \omega} \|S - REC_{\omega}(TF(P) * S)\|_2 + R(P) \quad (5)$$

其中, P 为随机滤光片结构参数向量, $TF(P)$ 为结构参数为 P 的随机透率, $TF(P) * S$ 为入射光经随机滤光片编码后的光强, REC_{ω} 为光谱重构网络, R 用于约束随机滤光片的结构参数范围。

3 像元映射变分辨率光谱成像

由 2.2 节知, 深度学习光谱编解码通过指定编码维度, 由欠完备自编码器完成该维度下的光谱特征提取与光谱信息重构, 因此编码维度的大小直接影响重构光谱与原始光谱的拟合精度。显然, 编码维度越高, 提取的特征维度越高, 重构的光谱也就越精细, 对应的分辨率就越高, 因而通过设定不同的编码维度可以实现不同分辨率的光谱复原。像元映射变分辨率光谱重构即利用以上思路, 基于像元级随机滤光片阵列光谱成像系统, 结合协同设计方法实现高精度的变分辨率光谱成像。

3.1 变分辨率光谱重构网络

本文利用欠完备自编码器的自动特征提取能力提出了像元映射变分辨率光谱成像, 通过将 16 种不同种类的随机滤光片以 2×2 阵列(共 4 组)和 4×4 阵列(共 1 组)进行组合以设定不同的编码维度, 然后并行训练出各个编码维度下对应分辨率的光谱重构网络。像元映射变分辨率光谱重构网络训练如图 4(彩图见期刊电子版)所示。

图 4 中为 2×2 阵列(编码维度为 4)与 4×4 阵列(编码维度为 16)光谱重构网络并行训练结构。原始光谱数据 S_{ORI} 为光谱图像数据集(由高分辨率成像光谱仪采集)中相邻 4 个像元的光谱数据。下面介绍随机滤光片结构参数优化与两个分辨率网络的并行训练过程。

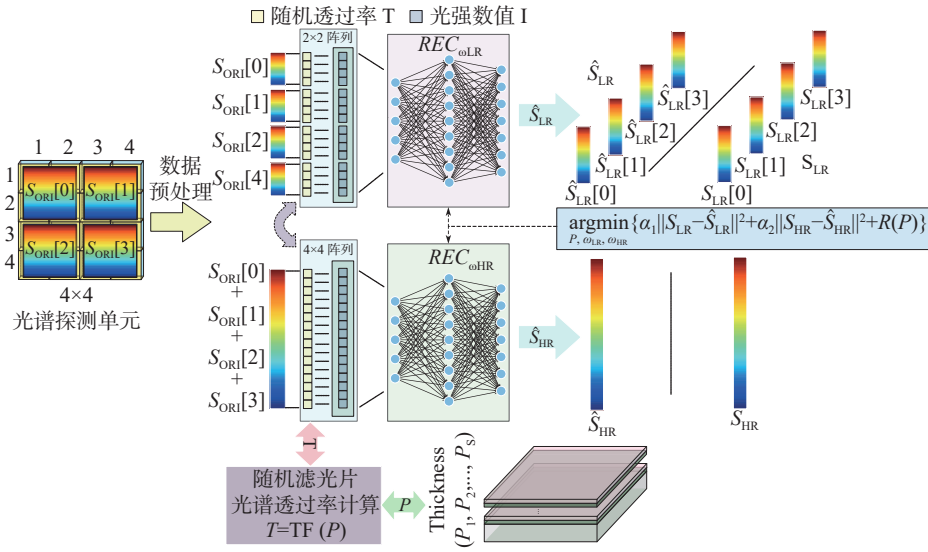


图 4 像元映射变分辨率光谱重构网络训练

Fig. 4 Spectral reconstruction network training of pixel mapping variable resolution

(1) 2×2 阵列重构网络训练过程: 每个像元的光谱数据由 4 类随机滤光片编码, 4 个像元需 4 组随机滤光片组(共 16 种随机滤光片), 将编码 (S_{ORI} 与 T 做点积运算) 后的 4 组光强数值(共 16 个)输入低分辨率重构网络 $REC_{\omega_{LR}}$ 进行重构, 输出 4 组低分辨率重构数据 \hat{S}_{LR} 分别与原始数据 S_{ORI} 的 4 组下采样 S_{LR} 进行拟合; (2) 4×4 阵列重构网络训练: 根据空间相邻像素的光谱相似性, 将原始数据 S_{ORI} 进行叠加, 得到组合像元的光谱数据(实际系统也是如此), 叠加后的光谱数据经 16 种随机滤光片编码, 将编码后的光强数值(共 16 个)

输入高分辨率重构网络 $REC_{\omega_{HR}}$, 输出高分辨率光谱数据 \hat{S}_{HR} 与原始数据 S_{ORI} 的叠加或 S_{ORI} 叠加的下采样 S_{HR} 进行拟合。

(1)、(2) 过程并行执行, 共用一套随机滤光片结构参数, 以均方误差加权和为损失值, 计算损失函数对网络参数的梯度, 反向传播调整网络参数和随机滤光片结构参数。重复这个过程直至损失值收敛接近零, 使得光谱数据 S_{ORI} 经随机滤光片编码后, 能被重构网络以较高的精度解码复原。像元映射变分辨率光谱重构网络优化表达如下:

$$\begin{aligned}
 T_{[n]} &= TF(P_{[n]}), n = 0, 1, \dots, 15 \quad ; \\
 \hat{S}_{HR} &= REC_{\omega_{HR}}(T_{[0..15]} * \sum_{i=0}^3 S_{ORI}[i]) \quad ; \\
 \hat{S}_{LR} &= REC_{\omega_{LR}}(T_{[0..3]} * S_{ORI}[0], T_{[4..7]} * S_{ORI}[1], T_{[8..11]} * S_{ORI}[2], T_{[12..15]} * S_{ORI}[3]) \quad ; \\
 (\hat{P}, \hat{\omega}_{LR}, \hat{\omega}_{HR}) &= \min_{P, \omega_{LR}, \omega_{HR}} \{ \alpha_1 \|S_{LR} - \hat{S}_{LR}\|_2 + \alpha_2 \|S_{HR} - \hat{S}_{HR}\|_2 + \lambda R(P) \} \quad . \quad (6)
 \end{aligned}$$

式中 α_1, α_2 为损失权重, 用于调整重点训练的网络。

3.2 随机滤光片参数约束

随机滤光片的结构参数主要有薄膜层数与每层薄膜的厚度。本文涉及的随机滤光片工作在可见光波段, 薄膜材料为 TiO_2 与 SiO_2 , 层数为 10。将每层薄膜的厚度作为优化参数, 同时将每层薄膜厚度约束在合理的工艺范围之内, 利用传输矩阵法计算给定结构参数下随机滤光片的透过率。训练过程中通过反向传播算法不断调整每一块随机滤光片各层薄膜的厚度, 使得在该组薄膜厚度

下的随机滤光片透过率对入射光谱的编码效率与重构精度最高。

此外, 光谱成像系统的能量增益由光学系统的 $F/\#$ 、滤光片的透过率、探测器的响应度和重构网络的放大率决定, 前两者限制了系统的光谱能量收集能力, 是光学设计和镀膜关注的重点, 后两者一定程度上影响系统的动态范围。利用随机滤光片与光谱重构算法协同设计方法, 通过设定合适的薄膜层数, 在训练过程中加入光谱能量约束, 即

$$C_1 \leq \frac{1}{\lambda_2 - \lambda_1} \int_{\lambda_1}^{\lambda_2} T_n(\lambda) d\lambda \leq C_2 (0 < C_1, C_2 < 1). \quad (7)$$

从而将随机滤光片的宽带透过率控制在较高范围内, 进一步提高光谱能量利用率与光谱重构网络的动态范围。

变分辨率光谱重构网络在整个训练过程对随机滤光片的结构参数与能量利用率进行约束优化, 使得随机滤光片组的透过率兼顾各个分辨率下光谱重构精度, 在全局上得到最优的随机滤光片光谱响应, 但对于单个分辨率网络却未必(由 α_1, α_2 调整)。

3.3 像元映射变分辨率光谱成像

前面讨论的是成像与光谱采集的基本单元(相当于成像光谱仪的一个像素), 要实现全视场的光谱图像采集, 需要通过扫描或者重复排列这些基本单元以历遍整个视场, 下面讨论重复排列基本单元形成面阵探测器以采集全视场光谱图像的方法。

利用光刻工艺, 将基本单元所需的随机滤光片设计成像元大小, 以 2 维阵列形式排列在玻璃基板上, 通过与探测器集成形成面阵光谱成像探测器。像元级随机滤光片阵列光谱成像系统如图 5(彩图见期刊电子版)所示。

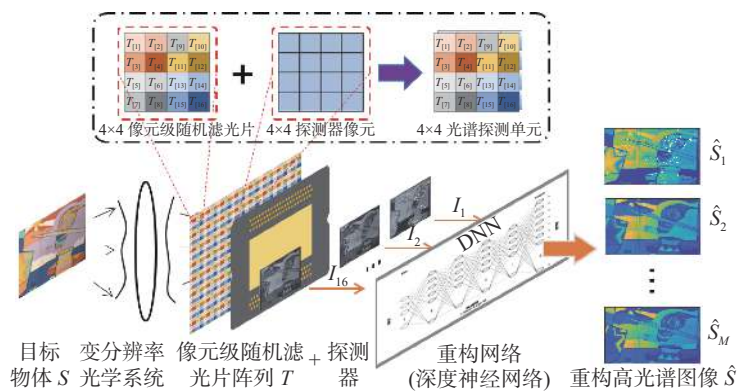


图 5 像元级随机滤光片光谱成像

Fig. 5 Pixel random filter spectral imaging

图 5 中成像与光谱采集的基本单元为 4×4 光谱探测单元。该单元通过在探测器的 4×4 像元上分别集成不同透过率、像元大小的随机滤光片完成对入射光光谱的编码与编码光强采集, 将 4×4 光谱探测单元周期性复制便可形成不同规模的光谱成像探测器。实际制作过程中, 根据探测器规模与像元大小设计像元级随机滤光片阵列, 在显微镜下通过高精度对准操作实现与探测器的集成。

为了实现光谱信息的精确采集, 需要根据探测任务选择合适的空间-光谱分辨率, 然后由变分辨率机构调整光学系统空间分辨率^[18-19], 使得入射同一组随机滤光片阵列的光来自物方同一区域。像元级随机滤光片变分辨率动态转换示意如图 6 所示。

图 6 中, 4×4 阵列利用 16 片随机滤光片对入射光谱进行采集, 光谱分辨率高而空间分辨率低; 2×2 阵列利用 4 片随机滤光片对入射光谱进行采集, 光谱分辨率低而空间分辨率高。变分辨率光学系统通过改变光学系统分辨率, 使得光学成像的最小弥散斑与对应的阵列大小相匹配, 从而实现变分辨率成像。

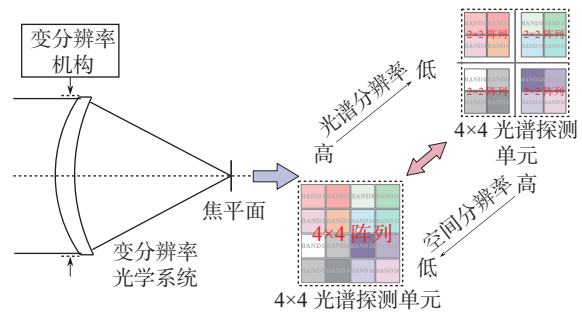


图 6 像元随机滤光片变分辨率动态转换示意

Fig. 6 Variable resolution dynamic conversion of a pixel random filter

光谱成像探测器完成光强编码图像的采集后, 依据每个 4×4 光谱探测单元的一个像元对应一种随机滤光片(共 16 种), 对探测器输出的图像像素进行分类, 得到由 16 种随机滤光片调制后的图像 $I_1 - I_{16}$, 将 $I_1 - I_{16}$ 输入对应的光谱重构网络完成整幅光谱图像的重构, 即

$$\hat{S} = REC_{\omega}(I) \quad ,$$

其中 \hat{S} 为重构光谱, $I = [I_1, I_2, \dots, I_{16}]$, REC_{ω} 为光谱

重构网络($REC_{\omega_{LR}}$ 或 $REC_{\omega_{HR}}$)。

4 实验仿真

使用 i7-10750H CPU 与 RTX2060 GPU, 通过 Windows 系统下 Pytorch 神经网络框架完成随机透过率曲线计算与重构网络训练。使用 ICVL (Interdisciplinary Computational Vision Laborator)^[20] 与 CAVE。光谱图像数据集, 抽取 430~470 nm 共 24 谱段、10 nm 分辨率的光谱图像, 为了平滑训练网络输出^[11], 将数据集沿光谱维插值至 120 谱段。

4.1 重构网络训练

搭建像元映射变分辨率光谱重构网络(如图 4 所示), 将光谱图像数据集输入光谱重构网络。其中, S_{ORI} 为光谱图像中空间相邻的 2×2 阵列、430~670 nm 光谱范围、120 谱段的光谱数据; S_{LR} 为 S_{ORI} 的 3 倍下采样, 即 S_{LR} 为 2×2 阵列、430~670 nm 光谱范围、40 谱段的光谱数据; S_{HR} 由 S_{ORI} 的空间像元叠加得到, 为 1×1 阵列、430~670 nm 光谱范围、120 谱段的光谱数据。选取权重因子比例

为 $\alpha_1 : \alpha_2 = 1 : 4$, 以平衡各个分辨率重构网络的训练。训练 500 轮后, 训练与验证损失值下降至 4×10^{-5} , 如图 7(彩图见期刊电子版)所示。

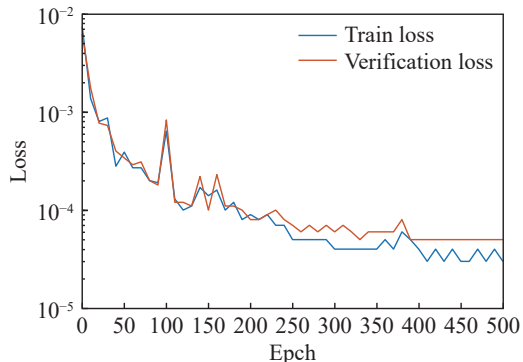


图 7 训练与验证损失曲线

Fig. 7 Training and verification loss curve

重构网络输出 \hat{S}_{LR} 为 2×2 阵列、430~670 nm 光谱范围、40 谱段的光谱数据; \hat{S}_{HR} 为 1×1 阵列 430~670 nm 光谱范围、120 谱段的光谱数据。

此外, 通过对随机滤光片进行能量约束, 设置 $C_1 = 0.5$, $C_2 = 0.7$, 训练得到的 16 片随机滤光片光谱透过率曲线 T 如图 8 所示。

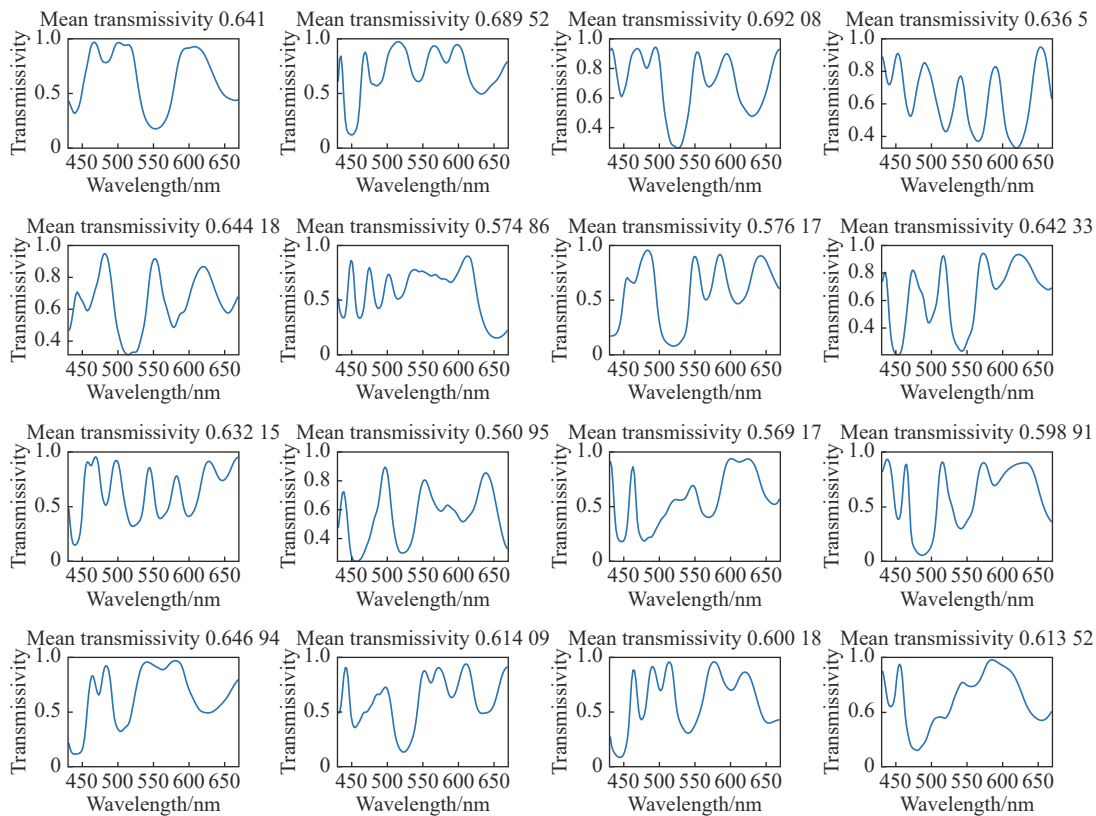


图 8 随机滤光片透过率曲线

Fig. 8 Transmission curves of random filter

其中,每一种随机滤光片的平均透过率均在 0.5~0.7 之间。

4.2 样本外验证

样本外验证结果如图 9(彩图见期刊电子版)所示,图 9(a)、9(b)、9(c)为 CAVE 样本外验证,光谱图像规格为 $512 \times 512 / 120$ 谱(插值),图 9(d)、9(e)为 ICVL 样本外验证,光谱图像规格为 $482 \times$

$482 / 120$ 谱(插值)。为了方便观察重构结果,从每幅光谱图像中选取两点,分别由红框(实线)和绿框(虚线)标出,GT 2×2 /GT 4×4 为真实的光谱曲线,REC 2×2 /REC 4×4 为重构的光谱曲线。

经计算,其中 2×2 阵列光谱重构 PSNR 达 46 dB、重构用时小于 709 ms, 4×4 阵列光谱重构 PSNR 达 56 dB、重构用时小于 457 ms。

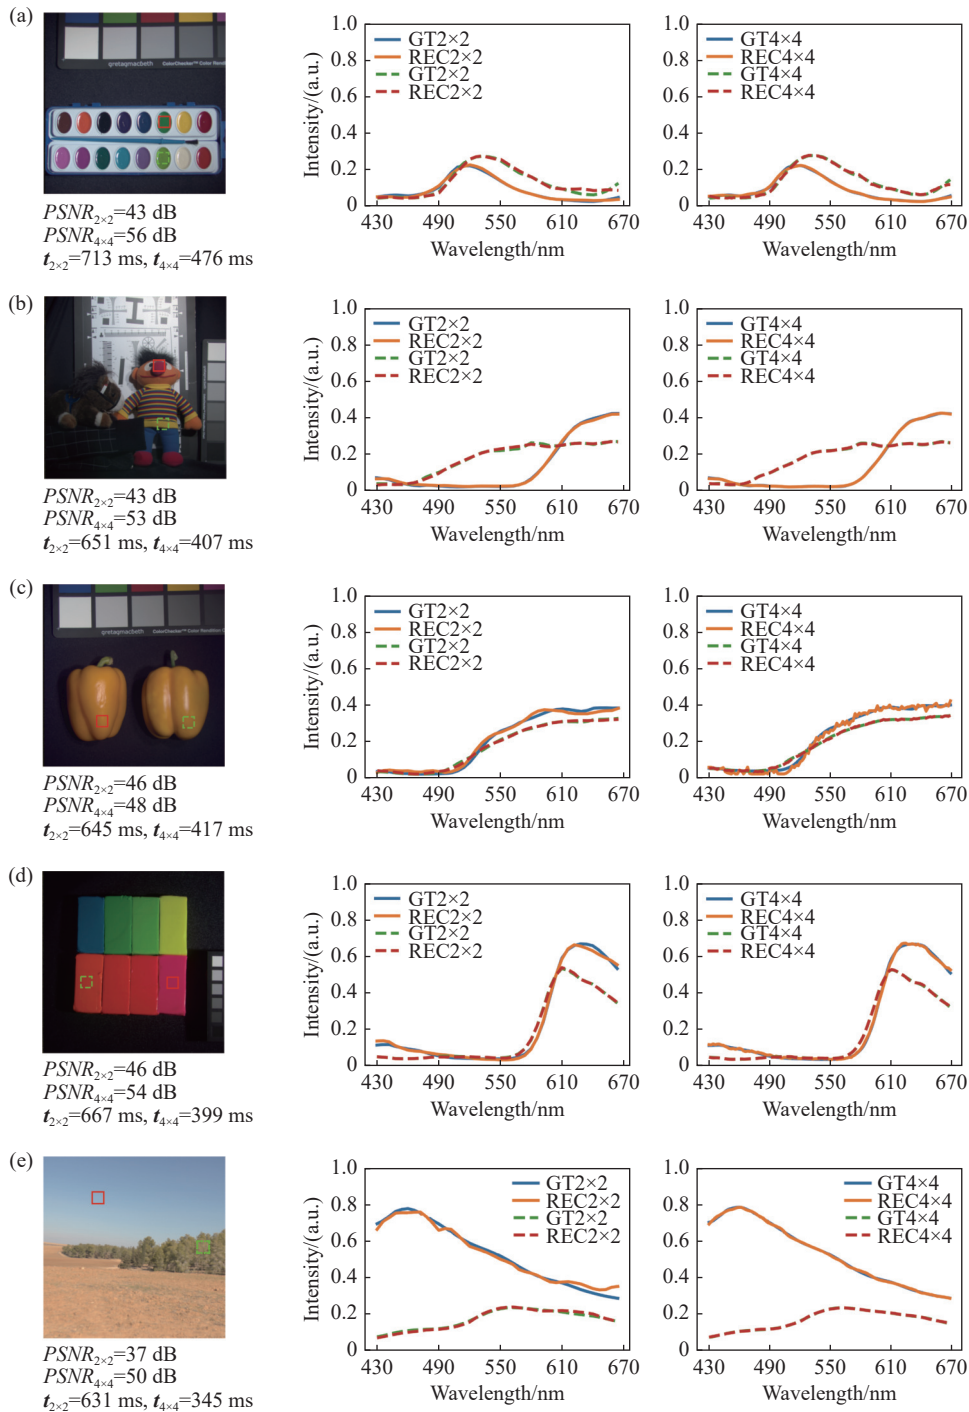


图 9 样本外预测结果

Fig. 9 Out-sample forecasting results

4.3 遥感高光谱图像验证

图 10(彩图见期刊电子版)为 KSC(Kennedy Space Center)遥感高光谱图像验证结果。图 10(a)是 KSC 的 RGB 遥感图像; 图 10(b)是 2×2 阵列重构 MSE; 图 10(c)是 4×4 阵列重构 MSE。可以

得出: 2×2 阵列重构 MSE 小于 0.002、每波段平均重构 MSE 小于 1.2×10^{-5} 、PSNR 达 53 dB、用时 869 ms, 4×4 阵列重构 MSE 小于 10^{-5} 、每波段平均重构 MSE 小于 1.5×10^{-6} 、PSNR 达 64 dB、用时 521 ms。

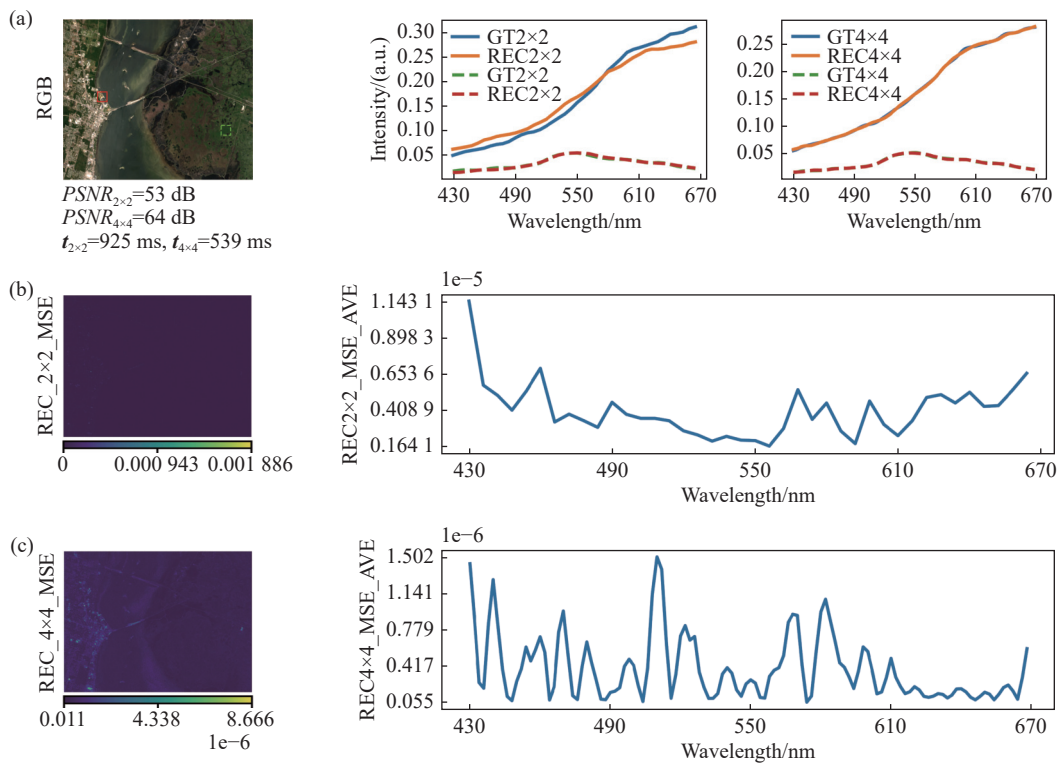


图 10 遥感高光谱图像验证结果

Fig.10 Remote sensing hyperspectral image verification results

5 结 论

本文论述了随机滤光片光谱编解码原理, 介绍了压缩感知与深度学习重构算法的基本原理, 阐述了随机滤光片与重构算法协同优化思想, 并受欠完备自编码器的自动特征提取机制的启发的基于协同优化方法的像元映射变分辨率光谱成像

重构算法。通过 CAVE 与 ICVL 数据集验证, 2×2 阵列光谱重构 PSNR 达 46 dB、重构用时小于 702 ms, 4×4 阵列光谱重构 PSNR 达 56 dB、重构用时小于 430 ms。遥感高光谱图像 2×2 阵列重构 MSE 小于 0.002、PSNR 达 53 dB, 4×4 阵列重构 MSE 小于 1.2×10^{-5} 、PSNR 达 64 dB, 具备精度高、重构速度快等特点。

参考文献:

- [1] LOBO J, DIAS J. Vision and inertial sensor cooperation using gravity as a vertical reference[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, 25(12): 1597-1608.
- [2] CORKE P, LOBO J, DIAS J. An introduction to inertial and visual sensing[J]. *The International Journal of Robotics Research*, 2007, 26(6): 519-535.
- [3] HAGEN N A, KUDENOV M W. Review of snapshot spectral imaging technologies[J]. *Optical Engineering*, 2013, 52(9): 090901.
- [4] YANG Z Y, ALBROW-OWEN T, CAI W W, et al.. Miniaturization of optical spectrometers[J]. *Science*, 2021,

- 371(6528): eabe0722.
- [5] 左超, 陈钱. 计算光学成像: 何来, 何处, 何去, 何从?[J]. *红外与激光工程*, 2022, 51(2): 20220110.
ZUO CH, CHEN Q. Computational optical imaging: an overview[J]. *Infrared and Laser Engineering*, 2022, 51(2): 20220110. (in Chinese)
- [6] ZHU X X, BIAN L H, FU H, *et al.*. Broadband perovskite quantum dot spectrometer beyond human visual resolution[J]. *Light:Science & Applications*, 2020, 9: 73.
- [7] YANG Z Y, ALBROW-OWEN T, CUI H X, *et al.*. Single-nanowire spectrometers[J]. *Science*, 2019, 365(6457): 1017-1020.
- [8] WANG ZH, YI S, CHEN A, *et al.*. Single-shot on-chip spectral sensors based on photonic crystal slabs[J]. *Nature Communications*, 2019, 10(1): 1020.
- [9] LEE W B, OLIVER J, KIM S C, *et al.*. Random optical scatter filters for spectrometers: implementation and estimation[C]. *Propagation Through and Characterization of Distributed Volume Turbulence 2013*, Optical Society of America, 2013: JTU4A. 33.
- [10] XIONG J, CAI X SH, CUI K Y, *et al.*. Dynamic brain spectrum acquired by a real-time ultraspectral imaging chip with reconfigurable metasurfaces[J]. *Optica*, 2022, 9(5): 461-468.
- [11] ZHANG W Y, SONG H Y, HE X, *et al.*. Deeply learned broadband encoding stochastic hyperspectral imaging[J]. *Light:Science & Applications*, 2021, 10: 108.
- [12] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [13] OLIVER J, LEE W, PARK S, *et al.*. Improving resolution of miniature spectrometers by exploiting sparse nature of signals[J]. *Optics Express*, 2012, 20(3): 2613-2625.
- [14] BARANIUK R, DAVENPORT M, DEVORE R, *et al.*. A simple proof of the restricted isometry property for random matrices[J]. *Constructive Approximation*, 2008, 28(3): 253-263.
- [15] CANDÈS E J. Compressive sampling[C]. *Proceedings of the International Congress of Mathematicians*, 2006: 1-20.
- [16] HUANG L Q, LUO R CH, LIU X, *et al.*. Spectral imaging with deep learning[J]. *Light:Science & Applications*, 2022, 11: 61.
- [17] 王雅思, 姚鸿勋, 孙晓帅, 等. 深度学习中的自编码器的表达能力研究[J]. *计算机科学*, 2015, 42(9): 56-60,65.
WANG Y S, YAO H X, SUN X SH, *et al.*. Representation ability research of auto-encoders in deep learning[J]. *Computer Science*, 2015, 42(9): 56-60,65. (in Chinese)
- [18] 冯驰, 常军, 杨海波. 双小凹光学成像系统设计[J]. *物理学报*, 2015, 64(3): 034201.
FENG CH, CHANG J, YANG H B. Design of dually foveated imaging optical system[J]. *Acta Physica Sinica*, 2015, 64(3): 034201. (in Chinese)
- [19] CHENG Y, CAO J, HAO Q, *et al.*. Compound eye and retina-like combination sensor with a large field of view based on a space-variant curved micro lens array[J]. *Applied Optics*, 2017, 56(12): 3502-3509.
- [20] ARAD, BEN-SHAHAR, *et al.*. Sparse recovery of hyperspectral signal from natural RGB images[C]. *Proceedings of the European Conference on Computer Vision, Amsterdam, The Netherlands, October 11-14, 2016*, 19-34. Springer.

作者简介:



肖树林(1996—), 男, 江西赣州人, 硕士研究生, 2020年于南昌航空大学获得学士学位, 主要从事智能图像处理、计算光谱成像方面的研究。
E-mail: 13263073168@163.com



胡长虹(1982—), 男, 吉林长春人, 副研究员, 博士生导师, 2013年于吉林大学获得博士学位, 2012—2013年在美国西弗吉尼亚大学做访问学者, 主要从事高光谱成像、计算成像、数据挖掘、软件质量评价方面的研究。
E-mail: changhonghu@rocketmail.com