

基于深度学习的滤光片型高光谱成像技术

林学利^{1,2}, 王子林^{1,2}, 邹艳霞^{1,2}, 刘豪^{1,2}, 郝然^{1,2}, 金尚忠^{1,2*}

¹中国计量大学光学与电子科技学院, 浙江 杭州 310018;

²浙江省现代计量测试技术及仪器重点实验室, 浙江 杭州 310018

摘要 相较于传统快照式高光谱成像技术, 基于深度学习的滤光片型高光谱成像技术仅使用深度学习和极少的滤光片进行光谱采样, 便能重建高光谱, 且滤光片直接与图像传感器集成, 具有结构简单、成像速度快等优点。但现有的研究大多直接以原高光谱成像仪拍摄的图像为数据集, 而未对数据集进行预处理, 忽略了原高光谱成像仪对数据集的影响。因此, 通过对原高光谱成像仪成像原理进行研究来对数据集进行预处理, 把高光谱图像转换为辐射功率谱, 从而消除原高光谱成像仪的影响, 增强了模型鲁棒性。另外, 鉴于滤光片存在光谱响应函数平滑性差而难以加工的问题, 将平滑性约束纳入误差函数的设计中, 使优化所得的滤光片具有平滑的光谱响应函数且易于加工。

关键词 光谱学; 高光谱成像; 计算光谱学; 光学逆向设计

中图分类号 TG115.3+39

文献标志码 A

DOI: 10.3788/LOP220984

Filtering Hyperspectral Imaging Technology Based on Deep Learning

Lin Xueli^{1,2}, Wang Zilin^{1,2}, Zou Yanxia^{1,2}, Liu Hao^{1,2}, Hao Ran^{1,2}, Jin Shangzhong^{1,2*}

¹College of Optical and Electronic Technology, China Jiliang University, Hangzhou 310018, Zhejiang, China;

²Key Laboratory of Zhejiang Province on Modern Measurement Technology and Instruments, Hangzhou 310018, Zhejiang, China

Abstract Deep learning-based filtering hyperspectral imaging technique can reconstruct hyperspectral images, which only requires deep learning and a few filters for spectral sampling. The filters are also directly integrated with the image sensor, resulting in a simple structure and quick imaging compared to typical snapshot hyperspectral imaging technology. However, most existing studies directly use the images taken by the original hyperspectral imager as the dataset without preprocessing, ignoring the impact of the original hyperspectral imager on the dataset. In this study, the dataset was preprocessed by examining the imaging mechanism of the original hyperspectral camera, which means that the hyperspectral image was converted into a radiative power spectrum to remove the effect of the original hyperspectral camera, resulting in a more robust model than in previous studies. Furthermore, because the spectral response function has poor smoothness, the filters are difficult to produce; thus, the smoothness constraint is incorporated into the error function to create a smooth and easy-to-produce filter.

Key words spectroscopy; hyperspectral imaging; computational spectroscopy; optical inverse design

1 引言

随着社会需求增加和科技发展, 光谱成像设备在各个领域有着广泛应用^[1-2], 其时间、空间与光谱分辨率都取得了长足的进步, 成像方式也逐渐发生着改变。基于 Bayer 滤光片阵列^[3]的 RGB 相机将原有场景丰富的光谱信息压缩至 RGB 三色中, 导致了一些问题的出现, 如信息丢失和同色异谱现象^[4]。为了保留更多的

信息, 高光谱成像系统(HISs)出现了。但传统高光谱成像大多以扫描的形式进行图像采集^[5-7], 这使得系统的时间分辨率、空间分辨率与光谱分辨率三者相互制衡。因此, 同时提高成像速度和成像质量成为了研究热点, 快照式高光谱成像借此出现^[8-10]。例如, Verde 公司^[11-12]基于计算机断层扫描光谱仪原理研制了一款高光谱成像仪, 该成像仪通过分光系统将原始空间光谱信息投影到二维传感器上, 以实现一次性曝光成像。

收稿日期: 2022-03-14; 修回日期: 2022-03-30; 录用日期: 2022-04-19; 网络首发日期: 2022-04-30

基金项目: 国家自然科学基金(61975182, 61575174)、浙江省重大科技计划项目(2020C03095)

通信作者: *jinsz@cjl.u.edu.cn

然而,这种方法对仪器的光学结构精度要求高,维护成本高。此外,其采集的原图像只占光敏平面面积的一部分,降低了图像空间分辨率。Zhu等^[13]提出了一种使用宽光谱的光子晶体(PC)滤光片的光谱探测方法,并展示了光子晶体材料用于光谱成像的可能性。

另一方面,有学者从降低光谱成像系统开发成本的角度进行了研究。匹兹堡大学的Chang等^[14]利用所述的宽光谱滤光片阵列,实现了片上的计算型光谱仪。后来,New Trends in Image Restoration and Enhancement workshop(NTIRE)对“从RGB图像重建高光谱图像”进行了多年的研究,试图通过RGB相机与深度学习相结合的方式获取高光谱图像。近几年来,众多学者以深度卷积神经网络(CNN)为基础进行光谱重建,取得了较好的重建结果。但在2020年的总结报告^[15]中专家们发现,卷积核自身特性致使其不可避免地周围像素极度敏感,训练完成的模型对打乱像素位置的图像的重构效果很差,使得模型并不能适应真实场景。在NTIRE理念的基础上,文献^[16]提出了将高光谱成像仪设计与机器学习相结合的理念,即通过神经网络层模拟光学元件的调制过程,并将三通道滤光片的设计嵌入到网络的训练当中实现同步优化。2021年,文献^[17-18]将高光谱相机设计与深度学习相结合,提出一种参数受限光谱编码器与解码器(PCSED),该方案能在提高光谱重建精度的同时实现对宽光谱滤光片的优化,具有成像速度快、光学结构简单、设计一体化等优点。然而,PCSED方案只考虑到原高光谱相机的光谱响应,忽略了相机本身曝光时间、感光度、白平衡等后期优化对相机输出带来的影响,使得数据集带有较多噪声,训练所得模型缺乏鲁棒性。

鉴于前人的研究和存在的问题,本文提出了一种基于特殊滤光片阵列的神经网络驱动高光谱成像仪设计方法,所提方法同样通过神经网络模拟成像过程,同步实现对滤光片的设计和光谱重建精度的提高。然而,文献^[17-18]在滤光片设计和实际高光谱图像重建中,分别设计了两个独立的神经网络模型。所提方法对两步工作进行了融合,仅需要训练一个独立的神经网络模型便可实现两个步骤。所提模型更为稳定,滤光片的结构不受约束,而且滤光片的光谱响应函数是平滑的,易于被熟练技工制造。这得益于两点:高光谱图像预处理,原高光谱成像仪对入射光信号进行过编码,引入了噪声,降低了系统的鲁棒性,因此引入原高光谱成像仪模型来对高光谱图像实施预处理;特殊的误差函数,为了使滤光片的光谱响应函数具有更好的平滑性,在神经网络的误差函数中引入一些约束条件。

2 高光谱成像仪设计

2.1 设计方法总览

所提设计方法主要由5个部分组成。1)建立光谱成像模型。本部分旨在模拟附有特殊滤光片的单

色相机成像过程,并设计光谱重建方法,实现从相机输出信号到原始“光谱”立方的映射。其中,光谱重建方法以神经网络为基础对映射关系进行学习,将特殊滤光片的光谱响应函数或结构参数作为可训练参数与神经网络共同迭代,同步实现重建精度提高与滤光片设计。2)采集训练图像。用现成的高光谱成像仪采集模型所需的图像集。3)预处理图像。对原高光谱成像仪进行建模,从而对其拍摄得到的图像进行预处理,去除原相机干扰。4)训练模型。根据需求设定所需相关训练参数,完成对模型的训练。5)加工与使用。将设计出的滤光片阵列按像素贴合置于单色相机光敏面上,结合训练完成的神经网络便可实现高光谱成像。其中,神经网络的具体参数是在参考前人工作的基础上进行了多次仿真测试才确立的,滤光片和相机成像过程的模拟中涉及的参数则是根据滤光片和相机的实际情况进行设置的。训练过程中,参数保持不变,网络权重和偏置值会随着迭代得到更新优化,训练完成后神经网络参数不再改变。另外,由于所设计的高光谱成像仪获取的是辐射功率谱,具体定标时还需选好前置光学系统,再对所述光谱成像仪进行图像采集,最后和标准光谱成像仪所拍摄的图像进行对比定标。

2.2 光谱成像模型

基于上述设计方法建立了光谱成像模型,该模型的光谱响应区间为400~700 nm,光谱分辨率 $\Delta\lambda$ 为10 nm。值得一提的是,光谱响应区间和光谱分辨率是由供给模型训练的数据集精度决定的,因此可根据不同精度的训练数据集训练出具有不同精度的模型,从而实现不同技术指标的光谱成像仪设计。所提光谱成像模型总共分为3个模块,如图1所示,分别是滤光片模块(Module 1)、单色相机成像模块(Module 2)及光谱重建模块(Module 3)。其中,滤光片模块和光谱重建模块主要由深度神经网络实现,深度神经网络克服了普通神经网络固有的梯度消失问题,通过添加更多网络层、向层内添加更多神经元,深度神经网络得已表示更复杂的函数。给定足够大的模型和足够大的标注训练数据集,深度神经网络便可通过学习将输入向量映射到输出向量。所用的深度神经网络是深度前馈网络(deep feedforward network),它是一种典型的深度学习模型。前馈网络的目标是近似某个函数,通过定义一个映射,并且学习映射的参数值,得到最佳的函数近似。一次学习的过程包含两个方向:一是如实线单箭头所表示的数据前向传播,用于计算模型误差;二是如虚线单箭头所表示的误差反向传播,用于将误差传递给网络中可以优化的参数。

所述模型成像过程分为两个步骤:1)一束复色光 $P_m(\lambda)$ 抵达覆盖有特殊滤光片的单色CCD相机感光面上,受到滤光片和相机的调制而产生相机响应值 O ;

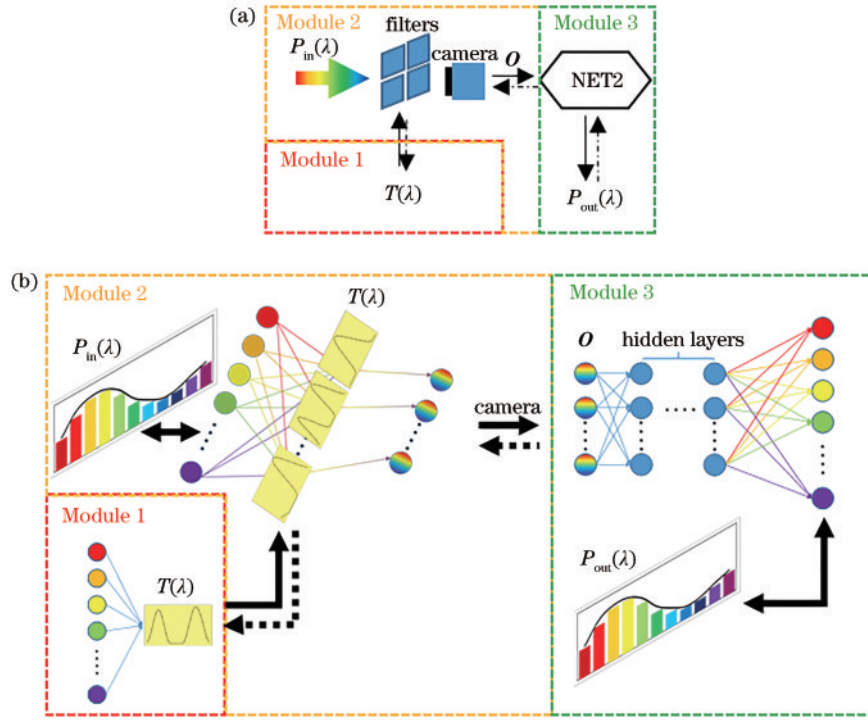


图 1 光谱成像模型。(a)原理图;(b)网络图

Fig. 1 Spectral imaging model. (a) Schematic of principle; (b) schematic of network

2)将 O 输入光谱重建模块中的神经网络 NET2, 计算重构得到原始复色光的辐射功率谱 $P_{out}(\lambda)$ 。Module 1 和 Module 2 负责实现步骤 1)。对于单像素, 步骤 1) 可以表示为

$$O = \frac{t_e}{hcK_c} \sum_{i=1}^{30} P_{in}(\lambda_i) T(\lambda_i) e_q(\lambda_i) \eta(\lambda_i) \lambda_i, \quad (1)$$

式中: O 为该像素的响应值; λ_i 为离散化后各谱段的中心波长; h 、 t_e 和 c 分别为普朗克常数、曝光时间和真空光速; $P_{in}(\lambda_i)$ 是 λ_i 处的入射辐射功率; $T(\lambda_i)$ 是 λ_i 处的滤光片光谱响应函数; $e_q(\lambda_i)$ 是图像传感器的量子效

率; $\eta(\lambda_i)$ 是图像传感器的量子转换增益率, 硅基光电探测器在 400~700 nm 谱段中的量子转换增益率近似为 1^[19]; K_c 表示相机后续电路中电荷电压转换、AD 转换等引入的信号数值变化系数, 由于该过程近似为线性变换, 所以使用单一转换以统一表示。

同理, $n \times n$ 大小的阵列滤光片覆盖下的响应值可以进一步表示为

$$O = MT, \quad (2)$$

式中: O 为响应值矩阵; M 为输入矩阵; T 为阵列滤光片的响应函数矩阵。它们中的具体元素分别为

$$\left\{ \begin{array}{l} O = [O_1 \ O_2 \ \dots \ O_{n^2}] \\ M = \frac{t_e}{hcK_c} [P_{in}(\lambda) * e_q(\lambda) * \lambda]^T = \frac{t_e}{hcK_c} \begin{pmatrix} P_{in}(\lambda_1) \\ P_{in}(\lambda_2) \\ \vdots \\ P_{in}(\lambda_{30}) \end{pmatrix} * \begin{pmatrix} e_q(\lambda_1) \\ e_q(\lambda_2) \\ \vdots \\ e_q(\lambda_{30}) \end{pmatrix} * \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_{30} \end{pmatrix}^T, \\ T = [T_1(\lambda) \ T_2(\lambda) \ \dots \ T_{n^2}(\lambda)] = \begin{pmatrix} T_1(\lambda_1) & T_2(\lambda_1) & \dots & T_{n^2}(\lambda_1) \\ T_1(\lambda_2) & T_2(\lambda_2) & \dots & T_{n^2}(\lambda_2) \\ \vdots & \vdots & \dots & \vdots \\ T_1(\lambda_{30}) & T_2(\lambda_{30}) & \dots & T_{n^2}(\lambda_{30}) \end{pmatrix} \end{array} \right. \quad (3)$$

式中: O_1 为 1 号滤光片对应像素的响应值; * 表示哈达马积。观察发现, 以一层线性(LN)层便可以实现式(2)的运算。如图 2 所示, 该 LN 层拥有 30 个输入与 n^2 个输出神经元。另外, 它的权重便是滤光片的光谱

响应值, 偏置值皆为 0。

另外, 为了比较不同制造工艺滤光片对光谱重建性能的影响, 设置了薄膜干涉滤光片和不限制结构的滤光片两种结构方案。其中, 特殊滤光片为不限制结




图 2 LN层模拟滤光片和相机对光的调制作用

Fig. 2 Simulation of light modulation by filter and camera based on LN layer

构的滤光片时, Module 1 中只含一层 LN 层, 其权重为滤光片的光谱响应函数, 设置为可训练权重, 并跟随网络训练进行优化; 特殊滤光片为薄膜干涉滤光片时, Module 1 还包含预先训练好的神经网络 NET1, 用于实现薄膜厚度和薄膜滤光片光谱响应函数的映射, 此时 NET1 的神经元权重和偏置是不随 NET2 训练而发生改变的。为了进行对比使用, 采用与文献[17]相同的薄膜干涉滤光片结构和 NET1 设计, 因此不再赘述。

Module 3 由一个纯粹的 BP 神经网络构成, 称为 NET2。NET2 的作用为学习 O 与 $P_{out}(\lambda)$ 的映射关系, 具体结构如表 1 所示。该网络的隐含层共有 14 层, 其中网络层分别为批标准化(BN)层、PReLU 激活函数层与线性(LN)层, 数字代表该层输入与输出神经个数, 具体模型代码已上传至 GitHub^[20] 供大家免费下载。Module 3 结构通过设置 BN 对数据实施批量标准化, 减少运算量, 降低发生梯度消失的概率; 通过设置斜率可学习的 PReLU 增强了网络的学习能力; 通过 LN 对数据进行维度变换, 以实现信息提取与压缩; 最后通过多组 BN-PReLU-LN 的结构实现整体网络的构建。

表 1 NET2 结构

Table 1 Structure of NET2

Layer	Input	Output
BN	n^2	n^2
PReLU	n^2	n^2
LN	n^2	600
BN	600	600
PReLU	600	600
LN	600	300
BN	300	300
PReLU	300	300
LN	300	100
BN	100	100
PReLU	100	100
LN	100	30
BN	30	30
PReLU	30	30

另外, 考虑到采用薄膜干涉滤光片的光谱成像系统优化得到的滤光片光谱响应函数复杂, 具有较多的峰谷, 这对加工精度提出了巨大的要求。因此, 设计了特殊的误差函数, 该函数由 3 个部分加权组合得到, 以实现不同功能的集成。第一部分, 以平均相对绝对误差(MRAE)^[15]来评估图像重构精度:

$$\epsilon_{MRAE} = \sum_{i=1}^{30} \frac{|P_{in}(\lambda_i) - P_{out}(\lambda_i)|}{30P_{in}(\lambda_i)}, \quad (4)$$

式中: $P_{out}(\lambda_i)$ 为 λ_i 处的重构辐射功率; ϵ_{MRAE} 为 MRAE, 相较于均方误差(MSE)函数, MRAE 采用相对误差来评估重构精度, 均衡了各波段绝对误差对总误差的贡献, 使得评价更为合理可信, 也利于网络的学习。

第二部分, 对滤光片的光谱响应值 $T_j(\lambda_i)$ 的取值范围 $[0, 1]$ 进行了限制, 公式为

$$\epsilon_{thT} = \sum_{j=1}^{n^2} \sum_{i=1}^{30} \max\left(\frac{T_j(\lambda_i) - T_{min}}{-\Delta} + 1, 0, \frac{T_{max} - T_j(\lambda_i)}{-\Delta} + 1\right), \quad (5)$$

式中: Δ 为超阈值放大因子, 取值为 0.01; 下标 j 表示阵列滤光片中滤光片的编号; T_{min} 和 T_{max} 分别是阈值下限和上限, 光谱响应值实际上就是滤光片的透射率, 针对加工难度和需求, 可以进行适当取值, 后续训练采用 $T_{min} = 0$, $T_{max} = 1$; ϵ_{thT} 为 $T_j(\lambda_i)$ 的超阈值误差, 当 $T_j(\lambda_i)$ 超出阈值时, ϵ_{thT} 会远大于 ϵ_{MRAE} , 从而迫使网络进行优化, 否则 $\epsilon_{thT} = 0$ 。

第三部分, 从滤光片光谱响应函数的峰谷数目、平滑性方面入手进行误差函数设计。主要设计思想与批标准化思想类似, 即将光谱响应函数 $T_j(\lambda)$ 的分布限制在适宜的范围内, 具体函数为

$$\begin{cases} \epsilon_T = \frac{1}{n^2} \sum_{j=1}^{n^2} |T_j^{(M)} - T_C^{(M)}| + \frac{1}{n^2} \sum_{j=1}^{n^2} |T_j^{(V)} - T_C^{(V)}| \\ \epsilon_{T^{(i)}} = \frac{1}{29n^2} \sum_{j=1}^{n^2} \sum_{i=1}^{29} |T_j^{(i)}(\lambda_i)| + \frac{1}{n^2} \sum_{j=1}^{n^2} \left| \sum_{i=1}^{29} T_j^{(i)}(\lambda_i) \right| \end{cases}, \quad (6)$$

式中: $T_j^{(i)}(\lambda_i)$ 为 $T_j(\lambda)$ 在 λ_i 处的一阶差分; $T_j^{(M)}$ 与 $T_j^{(V)}$ 分别是 $T_j(\lambda)$ 的均值和方差; $T_C^{(M)}$ 与 $T_C^{(V)}$ 分别是 $T_j(\lambda)$ 均值和方差的目标值; ϵ_T 为 $T_j(\lambda_i)$ 的异常分布误差, 当正向传播后的 $T_j^{(M)}$ 与 $T_j^{(V)}$ 偏离设置的目标值时, ϵ_T 急剧增大, 从而迫使网络优化 $T_j(\lambda_i)$, 最终使得 $T_j^{(M)}$ 处于合适水平, 上下震荡幅度适宜, 目标值可根据具体需求进行相应设置, 采用经验值 $T_C^{(M)} = 0.3$, $T_C^{(V)} = 0.16$; $\epsilon_{T^{(i)}}$ 为 $T_j^{(i)}(\lambda_i)$ 的异常波动误差。薄膜干涉滤光片的光谱响应函数峰谷数目多、抖动大, 这些现象在数值方面的体现就是光谱响应函数的导数太大且正负变化频繁。因此在大小方面限制 $T_j^{(i)}(\lambda_i)$ 绝对值目标为 0, 在方向方面限制其累计值目标为 0, 两者越接近 0, 意味着滤光片光谱响应函数变化更缓、拐点更少, 从而减少滤光片光谱突变, 并使得滤光片光谱整体上升/下降幅度近似。

综上,总的误差函数可表示为

$$\epsilon_0 = \epsilon_{\text{MRA}} + \alpha \epsilon_{\text{ht}} + \beta (\epsilon_T + \epsilon_{T^{(i)}}), \quad (7)$$

式中: α 与 β 分别是 ϵ_{ht} 与 $(\epsilon_T + \epsilon_{T^{(i)}})$ 的权重,需根据实际加工需求和训练收敛情况进行选择,最终使用 $\alpha = 0.002, \beta = 0.4$ 。

2.3 数据集采集与预处理

如前文所述,直接采用原高光谱成像仪输出的高光谱图像进行模型训练是不可取的,因此所提方法对

图像集进行了预处理。所举的案例将采用跨学科计算视觉实验室(ICVL)免费提供的raw高光谱数据集进行仿真实验^[21],拍摄设备为SPECIM公司的PS Kappa DX4型高光谱成像仪。该款高光谱成像仪是一台扫描式光谱成像仪,由一台光谱仪和一台单色CCD相机组合而成。通过光谱仪进行分光并用单色相机进行逐行的图像采集,实现高光谱的获取,具体成像原理如图3所示。

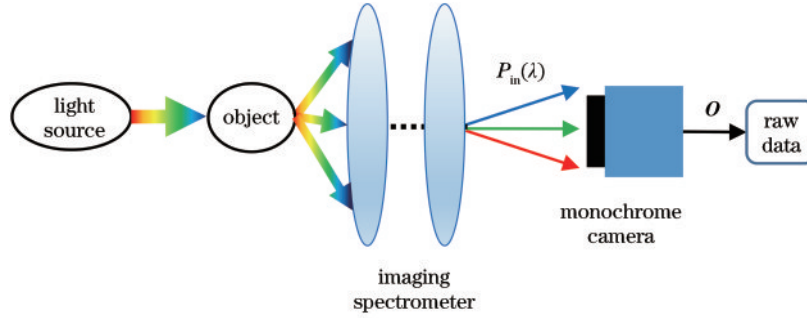


图3 PS Kappa DX4型高光谱成像仪的成像原理

Fig. 3 Imaging principle of PS Kappa DX4 hyperspectral camera

ICVL制作图像集时是采用raw格式进行图像存储的,这意味着输出信号并未受到后续的白平衡等图像处理手段的影响,只含有单色CCD相机对入射辐射功率的调制作用。因此,其成像过程与本文所述单色相机相同,但由于其内置光谱仪的分光作用以及不含滤光片,所以其内单色相机接收到的是单色光,当入射波长为 λ_i 时,单像素的响应值应满足

$$O = \frac{t_e}{hcK_C} P_{\text{in}}(\lambda_i) e_q(\lambda_i) \eta(\lambda_i) \lambda_i. \quad (8)$$

为了去除原高光谱成像仪的影响,还需要知道参数信息。该款高光谱成像仪已知的几个参数是:光谱响应范围为400~1000 nm、像素分辨率为 1392×1040 、光谱分辨率为1.25 nm、动态范围12 bit、像素尺寸为 $6.45 \mu\text{m}$ 、曝光时间为 $1 \mu\text{s} \sim 120 \text{s}$ 。然而,式(8)中还存在部分参数未知,如 $e_q(\lambda_i)$ 、 t_e 以及 K_C 。但实际上并不是所有参数都需要精确还原的,因为除了原高光谱成像仪的调制外,散粒噪声、热噪声等是无法完全去除的,反而通过设置合适的参数, $P_{\text{in}}(\lambda)$ 覆盖日常照明的强度范围,能使训练得到的模型更加具有鲁棒性。因此以索尼ICX285AL款单色CCD的量子效率^[22]作为 $e_q(\lambda_i)$ 进行模型训练, t_e 与 K_C 则要根据实际照明环境进行设置。根据式(8)和人眼明视觉函数 $V(\lambda_i)$,可以计算出对应的辐射照度,具体计算过程为

$$P_c(\lambda_i) = \int E_c(\lambda_i) dA = \int \frac{E_v(\lambda_i)}{683V(\lambda_i)} dA \approx \frac{E_v(\lambda_i)}{683V(\lambda_i)} \times A, \quad (9)$$

式中: $P_c(\lambda_i)$ 与 $E_c(\lambda_i)$ 分别是辐射功率和辐射照度;

$E_v(\lambda_i)$ 和 A 分别是光照度和感光面积。由于单位像素面积仅有 $36 \mu\text{m}^2$ 左右,所以功率分布可视为均匀,即式(9)中的约等于关系。此时若相机响应值为饱和状态,即 O 在10 nm间隔的400~700 nm波长范围内皆达到动态范围最大值 $2^{12} - 1 = 4095$,再设置 $K_C = 200$ ^[19]与 $t_e = 1 \text{ms}$,便能计算出总的光照度数值,约为 $12 \times 10^4 \text{lx}$,与晴天后室外光照度相近。

3 分析与讨论

3.1 验证方案

从ICVL提供的数据库中收集了203个“光谱立方”raw数据,即高光谱图像。其中,高光谱图像的光谱采样分辨率为10 nm,光谱响应区间为400~700 nm。随后,进行数据预处理,并随机选取了162幅图像作为光谱成像模型的训练集,其余41幅作为测试集。另外,所述光谱成像系统的单色相机是以上海昊量光电设备公司生产的CinCam CCD-2302相机^[23]为原型进行优化设计的。出于方便考虑,优化过程中 t_e 和 K_C 保持与预处理时一致,但这只是增加系统使用时的限制,即需设定同样的参数才能达到更好的光谱成像效果。

最后,为了比较薄膜干涉滤光片与不限制结构的滤光片的性能差异,以 2×2 阵列为例,分别采用薄膜干涉滤光片和不限制结构滤光片但其他条件都保持一致的两种方案进行仿真比较实验,后文称为实验一。鉴于不限制结构的滤光片方案的优越性,对不同的阵列大小对光谱成像性能的影响展开进一步探究,因此设计了 3×3 和 4×4 阵列大小的不限制结构滤光片方

案,并采用相同的网络结构进行了仿真实验,后文称为实验二。

3.2 实验一

从测试集中随机挑选了 3 幅“光谱立方”,将其输入训练好的光谱成像模型,输出的光谱重构结果如图 4 所示。图 4(a)中 RGB 列展示原高光谱立方的 RGB 图像,tf MRAE 与 nl MRAE 列分别是采用薄膜(tf)结构与无限制(nl)结构滤光片的光谱成像系统的 MRAE 灰度图。其中,灰度值与对应像素的 MRAE

数值对应,颜色深浅代表了该像素光谱重构性能的好坏。tf MRAE hist 与 nl MRAE hist 分别是两种方案下的 MRAE 直方图,表征了 MRAE 的像素分布,横轴表示不同的 MRAE,纵轴表示对应的像素数目。其中设定 MRAE 阈值为 0.02,以小于这个阈值的像素占整幅图像像素数的比例 percent、平均值 mean、中位数 median 这三个指标定量地展示不同方案下的重构结果,通常认为 MRAE 小于 0.02 表示光谱重构结果较好^[15]。

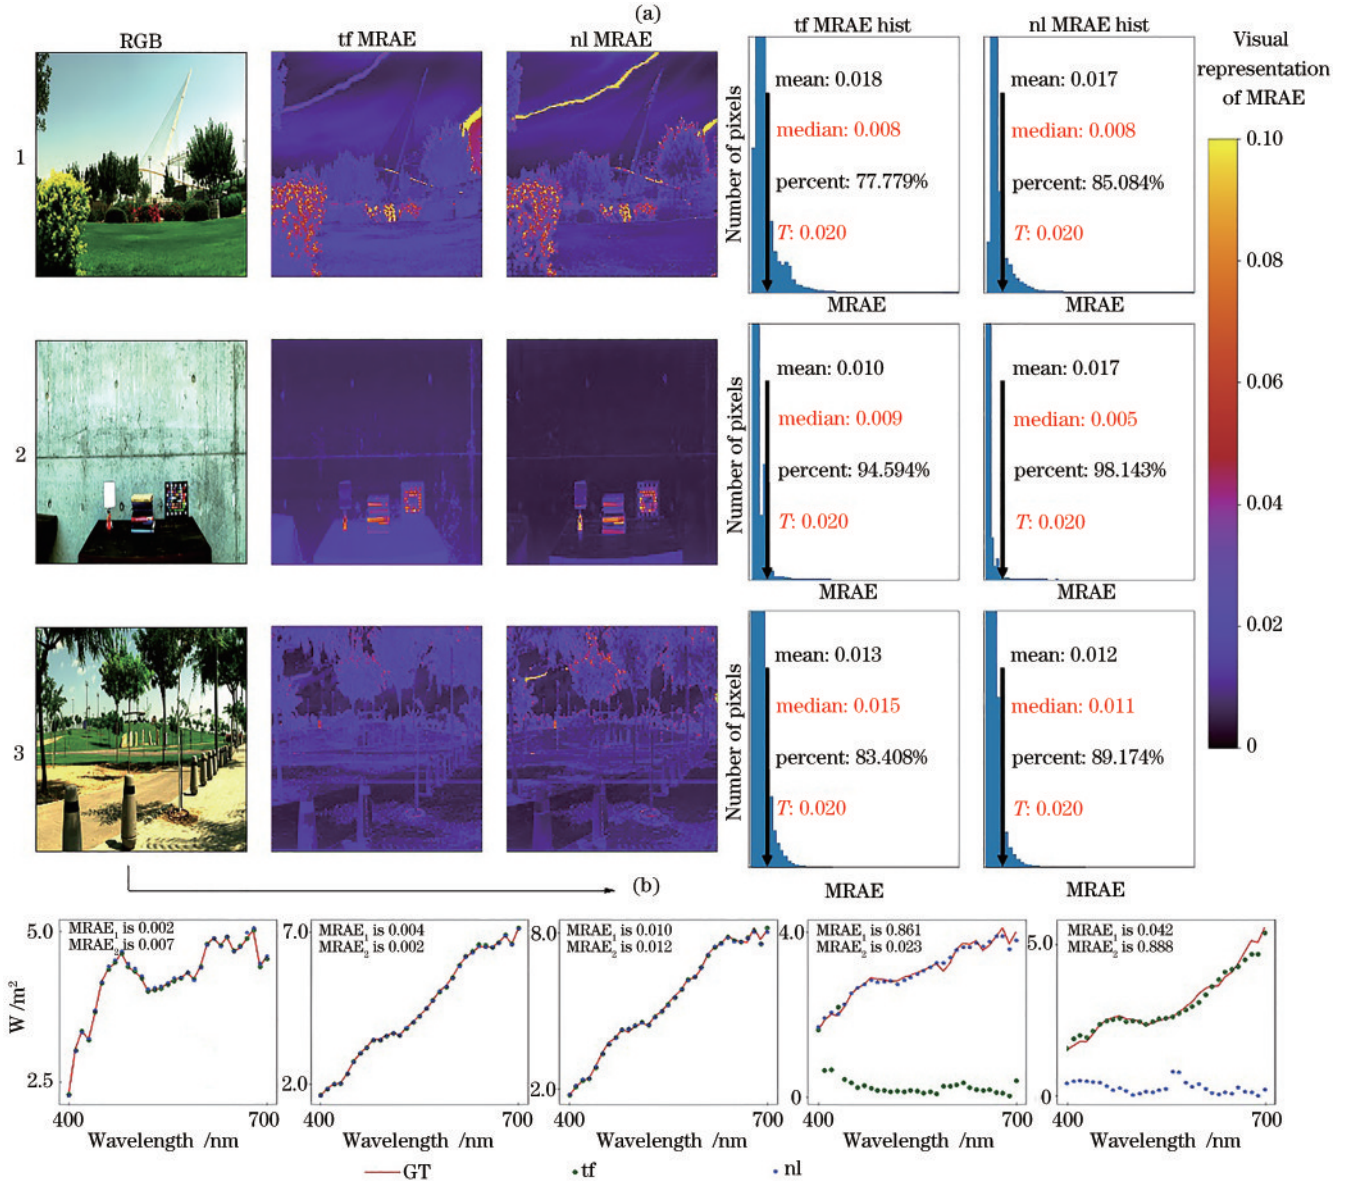


图 4 两种结构滤光片方案优化所得模型的光谱重构性能对比。(a) RGB 图、tf MRAE 和 nl MRAE 灰度图、tf MRAE hist 与 nl MRAE hist 直方图;(b)编号 3 的部分像素重构辐射照度

Fig. 4 Comparison of the spectral reconstruction performance of the optimized model with two structural filter schemes. (a) RGB image, tf MRAE and nl MRAE images, tf MRAE hist and nl MRAE hist images; (b) reconstructed irradiance of some pixels in sample No. 3

对比 tf MRAE 与 nl MRAE 列可以看出,图像的色调分布大致相同,但在不同的像素位置,两种方案各有优势。例如编号 2 的图像包含三个色彩分明的物体:

红色火箭、不同颜色的书籍以及色卡,相较于背景部分(墙壁和桌子),它们光谱重构难度更高。此时,对比发现 nl MRAE 的背景部分更为黑暗,而三个特殊物体部

分却显得更为亮黄,这意味着不限制结构滤光片方案对简单光谱的重构效果要优于薄膜干涉滤光片方案,而对复杂光谱则相反。

众所周知,直方图更能展现整体的数据分布,因此使用 MRAE 的像素分布直方图来进一步对比两种方案的重构性能。分别如 tf MRAE hist 与 nl MRAE hist 列所示,所给的 3 个定量指标都表明不限制结构的滤光片方案优于薄膜干涉滤光片方案,综合对 MRAE 灰度图的讨论结果,这可能是大部分场景中还是以背景物体居多、光谱复杂的物体较少导致的。

为了更直观地观察光谱重构结果,从编号为 3 的“光谱立方”中挑选了 5 个像素,直接展示其原始的辐射照度谱和重构的辐射照度谱,如图 4(b)所示。它们从左到右分别属于采用薄膜干涉方案时 MRAE 最小的像素、采用不限制结构方案时 MRAE 最小的像素、采用薄膜干涉方案时 MRAE 为 0.01 的像素、采用薄膜干涉方案时 MRAE 最大的像素、采用不限制结构方案时 MRAE 最大的像素。在前 3 张图片中,两种方案的重构

辐射照度与真实值基本吻合,这也从侧面证明了 MRAE 在 0.01 附近时的重构性能。第 4 幅图与第 5 幅图则分别是两种方案重构最差的像素,两种方案重构性能差异十分明显,这可能是网络训练的偶然性导致的。

综上所述,两种方案的重构性能各有优势:薄膜干涉滤光片方案对重构目标的光谱复杂性具有较强适应性;不限制结构滤光片方案对光谱简单的目标重构性能较好,而对光谱复杂的则较差。然而,考虑到实际拍摄中关键目标所占图像像素的比例往往不高,因此就统计角度而言,不限制结构滤光片方案能够更好地重构“光谱立方”。

另外,两种方案设计所得的 4 块滤光片光谱响应函数如图 5 所示。就加工难度,薄膜结构滤光片光谱响应函数复杂,且对膜厚有着严格要求,不易于加工;然而,不限制结构的滤光片方案光谱变化平缓,峰谷数目少,对于熟练制造工而言容易制造。因此,从成本和加工角度考虑,不限制结构的滤光片方案更适合于光谱成像系统的阵列滤光片设计。

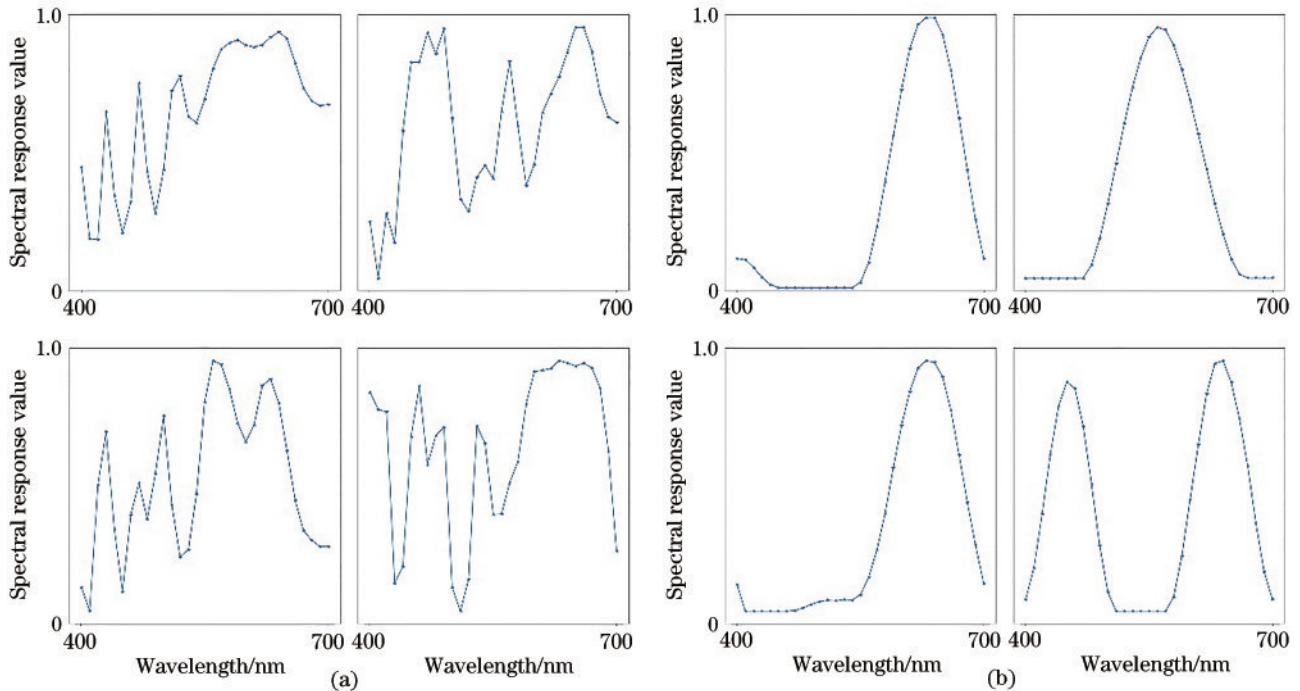


图 5 优化后滤光片的光谱响应函数对比。(a)薄膜干涉滤光片方案;(b)不限制结构滤光片方案

Fig. 5 Comparison of the optimized filter's spectral response function. (a) Thin film interference filter scheme; (b) no-limited structure filter scheme

3.3 实验二

将进一步探究不同阵列大小对不限制结构滤光片方案下光谱成像系统重构性能的影响。结果图排列方式与图 4 类似,具体如图 6 所示。与图 4 相结合,可以比较 2×2 、 3×3 与 4×4 方案的重构性能差异。总体上随着阵列大小的增加,重构性能得到了提升,这是因为提供了更多路的信号供网络进行学习;另外,相较于 2×2 方案, 3×3 方案下的 MRAE 灰度图像色调更暗,亮点更少,这表明 3×3 方案的重构性能整体要优于 2×2 方

案,这点从 MRAE 的像素分布直方图中也可以看出, 3×3 方案在三个定量指标 mean、median 和 percent 上都显著优于 2×2 方案;最后,相对 3×3 方案, 4×4 方案下 MRAE 灰度图的色调略有变暗,从 MRAE 像素分布直方图中也能看出,各项指标略微提升,三个主要参数得到了改进,所选像素重建值与真值基本重叠。在这些方面, 4×4 方案优于 3×3 方案,但差别不大。

另外,除重建精度外还应考虑图像传感器感光面的空间利用率。随着阵列的增大,空间利用率从 $1/4$

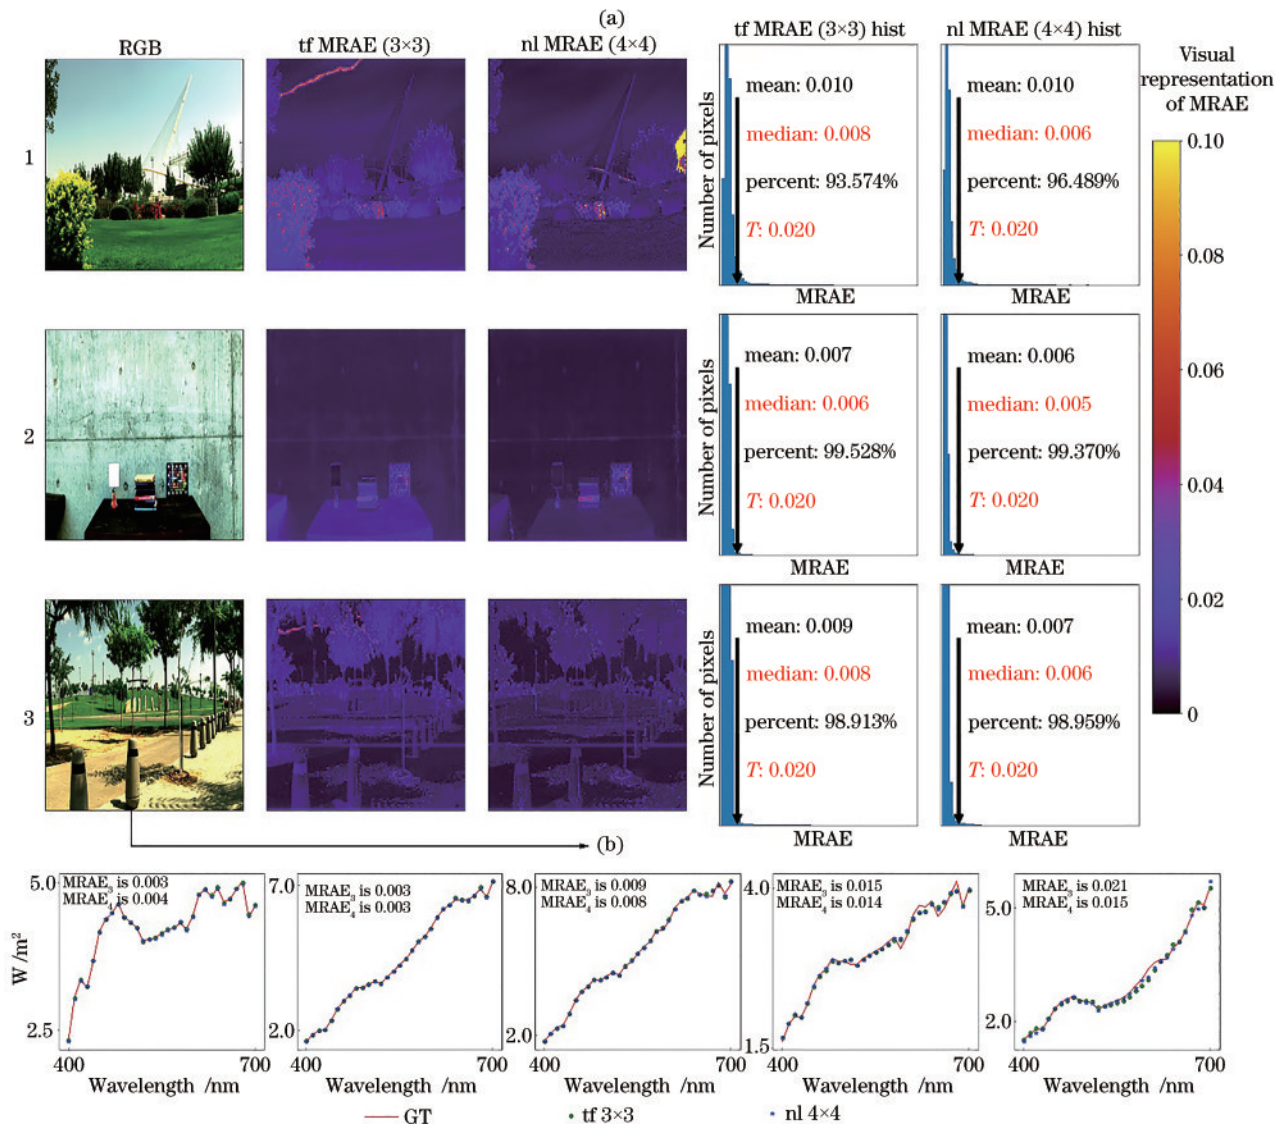


图 6 不同阵列大小对采用无限制结构的光谱成像性能的影响。(a) RGB 图、tf MRAE 和 nl MRAE 灰度图、tf MRAE hist 与 nl MRAE hist 直方图；(b) 编号 3 的部分像素重构辐射照度
Fig. 6 Impact of various array sizes on the spectral imaging performance of no-limited structure filters. (a) RGB image, tf MRAE and nl MRAE images, tf MRAE hist and nl MRAE hist images; (b) reconstructed irradiance of some pixels in sample No. 3

急剧下降到 1/16, 下降了 75% 之多, 但性能上只有 15% 左右的提升。因此, 认为 3x3 阵列大小是无限制结构滤光片方案的最好选择。

4 结 论

提出了一种基于机器学习的滤光片型快照式光谱成像系统设计方法, 并举例验证了所提方法的可行性。仿真结果发现: 薄膜结构方案下优化得到的滤光片光谱响应函数存在许多峰谷, 虽然能得到具体的结构参数, 但对于所设计的高光谱成像仪稳定性很不利; 无限制滤光片结构的方案优化得到的滤光片光谱响应函数较为平滑, 稳定性好。后续对两种方案中滤光片数目对重构精度的影响进行了研究, 随着滤光片数目增多, 重构性能得到提升, 空间利用率下降。尤其在 3x3 大小的滤光片阵列下, 平均每幅图像有 95% 的像素的平

均相对绝对误差小于 0.02, 即取得了较好的重构精度, 考虑到 4x4 大小阵列下精度提升较小且空间利用率减半 (9/16), 3x3 的方案是较好的选择。

对所设计的成像光谱仪进行了仿真研究, 所提设计方法给便捷、低成本、高性能的成像光谱仪设计提供了一种研制途径。但在成像过程模拟时, 尚未考虑噪声的影响, 例如光子噪声、散粒噪声等, 后续研究可以对现成的成像光谱仪进行更精确的模型推导与数据还原, 并通过实际设计实验来定标本光谱成像模型。

参 考 文 献

[1] 王健, 崔天翔, 王一, 等. 高分五号可见短波红外高光谱影像云检测研究[J]. 光学学报, 2021, 41(9): 0928003. Wang J, Cui T X, Wang Y, et al. Cloud detection for GF-5 visible-shortwave infrared advanced hyperspectral

- image[J]. *Acta Optica Sinica*, 2021, 41(9): 0928003.
- [2] 朱首正, 卜令兵, 刘继桥, 等. 机载高光谱分辨率激光雷达探测大气气溶胶光学特性及污染研究[J]. *中国激光*, 2021, 48(17): 1710003.
Zhu S Z, Bu L B, Liu J Q, et al. Study on airborne high spectral resolution lidar detecting optical properties and pollution of atmospheric aerosol[J]. *Chinese Journal of Lasers*, 2021, 48(17): 1710003.
- [3] Cheremkhin P A, Lesnichii V V, Petrov N V. Use of spectral characteristics of DSLR cameras with Bayer filter sensors[J]. *Journal of Physics: Conference Series*, 2014, 536: 012021.
- [4] Wu J L, Wei M C, Fu Y, et al. Color mismatch and observer metamerism between conventional liquid crystal displays and organic light emitting diode displays[J]. *Optics Express*, 2021, 29(8): 12292-12306.
- [5] Gasser C, González-Cabrera M, Ayora-Cañada M J, et al. Comparing mapping and direct hyperspectral imaging in stand-off Raman spectroscopy for remote material identification[J]. *Journal of Raman Spectroscopy*, 2019, 50(7): 1034-1043.
- [6] 赵峰. 一种用于海洋赤潮监测的多光谱高分辨相机设计[D]. 哈尔滨: 哈尔滨工业大学, 2019: 1-58.
Zhao F. A multi-spectral high-resolution camera design for marine red tide monitoring[D]. Harbin: Harbin Institute of Technology, 2019: 1-58.
- [7] 王磊. 一种推扫式高光谱成像仪的编码孔径压缩采样设计与实现[D]. 长沙: 国防科技大学, 2017: 1-52.
Wang L. A push-broom hyperspectral imager with coded aperture compressive sampling design and implementation [D]. Changsha: National University of Defense Technology, 2017: 1-52.
- [8] Geelen B, Tack N, Lambrechts A. A compact snapshot multispectral imager with a monolithically integrated per-pixel filter mosaic[J]. *Proceedings of SPIE*, 2014, 8974: 89740L.
- [9] 陈建因, 李卉, 马雯莹, 等. 八腔带通腔体滤波器器的设计[J]. *雷达与对抗*, 2019, 39(4): 46-49.
Chen J N, Li H, Ma W Y, et al. Design of an eight-cavity band-pass cavity filter[J]. *Radar & ECM*, 2019, 39(4): 46-49.
- [10] Tanriverdi F, Schuldt D, Thiem J. Dual snapshot hyperspectral imaging system for 41-band spectral analysis and stereo reconstruction[M]//Bebis G, Boyle R, Parvin B, et al. *Advances in visual computing. Lecture notes in computer science*. Cham: Springer, 2019, 11845: 3-13.
- [11] Wang X C, He Y, Meng Z K. Color sensitive characteristic of CIE(X, Y, Z) color space[J]. *Proceedings of SPIE*, 2006, 6033: 60330B.
- [12] Johnson W R, Wilson D W, Fink W, et al. Snapshot hyperspectral imaging in ophthalmology[J]. *Journal of Biomedical Optics*, 2007, 12(1): 014036.
- [13] Zhu Y B, Lei X, Wang K X, et al. Compact CMOS spectral sensor for the visible spectrum[J]. *Photonics Research*, 2019, 7(9): 961-966.
- [14] Chang C C, Lee H N. On the estimation of target spectrum for filter-array based spectrometers[J]. *Optics Express*, 2008, 16(2): 1056-1061.
- [15] Arad B, Timofte R, Ben-Shahar O, et al. NTIRE 2020 challenge on spectral reconstruction from an RGB image [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 14-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1806-1822.
- [16] Nie S J, Gu L, Zheng Y Q, et al. Deeply learned filter response functions for hyperspectral reconstruction[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4767-4776.
- [17] Song H Y, Ma Y G, Han Y B, et al. Deep-learned broadband encoding stochastic filters for computational spectroscopic instruments[J]. *Advanced Theory and Simulations*, 2021, 4(3): 2000299.
- [18] Zhang W Y, Song H Y, He X, et al. Deeply learned broadband encoding stochastic hyperspectral imaging[J]. *Light: Science & Applications*, 2021, 10(1): 108.
- [19] 张晨. 高速线阵 CCD 相机设计、实现及其应用研究[D]. 武汉: 武汉大学, 2017: 1-113.
Zhang C. Design, implementation and application research of high speed linear CCD camera[D]. Wuhan: Wuhan University, 2017: 1-113.
- [20] The-design-of-hyperspectral-camera-based-on-neural-network [EB/OL]. [2022-02-03]. <https://github.com/Lxl-CJLU/the-design-of-hyperspectral-camera-based-on-neural-network>.
- [21] Arad B, Ben-Shahar O. Sparse recovery of hyperspectral signal from natural RGB images[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9911: 19-34.
- [22] THorlabs. Sony ICX285AL Monochrome CCD [EB/OL]. [2021-02-05]. https://www.thorlabs.com/images/TabImages/1500M_QE.xlsx.
- [23] 上海昊量光电设备公司. CinCam CCD 数据表 [EB/OL]. [2022-02-03]. http://www.cinogy.com/CinCam_CCD_DataSheet.pdf.
Cinogy. Cincam CCD data sheet [EB/OL]. [2022-02-03]. http://www.cinogy.com/CinCam_CCD_DataSheet.pdf.