

基于单幅多光谱图像的照明光谱估计方法

鲁洋, 徐海松*

浙江大学光电科学与工程学院现代光学仪器国家重点实验室, 浙江 杭州 310027

摘要 由于场景的光谱信息受到不同照明条件的影响,故在照明不可控场景下拍摄的多光谱图像的光谱反射比重构需要进行照明光谱估计。因此,提出了一种基于单幅多光谱图像的通用方法来准确预测场景的照明光谱。首先,通过分析每个像素的响应特性设计并计算色度权重图,以寻找包含更多照明信息的像素。然后,对加权后的图像进行成分分析,以在通道域中提取光源响应特征。最后,得益于创新性引入的基于照明光谱库训练的字典学习方法,可估计出场景光源的相对光谱功率分布。所提方法在模拟数据和真实数据上的照明光谱估计平均角度误差分别为 0.29 和 3.42,与现有的同类方法相比,表现出更优的准确性和鲁棒性。

关键词 颜色; 多光谱成像; 光源光谱估计; 色度权重图; 字典学习; 光谱功率分布

中图分类号 O432

文献标志码 A

doi: 10.3788/AOS202242.0733001

Illumination Spectrum Estimation Method Based on Single Multispectral Image

Lu Yang, Xu Haisong*

State Key Laboratory of Modern Optical Instrumentation, College of Optical Science and Engineering, Zhejiang University, Hangzhou, Zhejiang 310027, China

Abstract The spectral information of the scene is affected by different illumination conditions, hence the spectral reflectance reconstruction of multispectral images taken under scenes with uncontrollable illumination requires illumination spectrum estimation. Therefore, a general method based on a single multispectral image is proposed to accurately predict the illumination spectrum of the scene. First, by analyzing the response features of each pixel, the chroma weight map is designed and calculated to find the pixels that contain more illumination information. Then, the component analysis of the weighted image is carried out to extract the illuminant response features in the channel domain. Finally, benefiting from the innovative introduction of the dictionary learning method trained by illumination spectrum library, the relative spectral power distribution of the scene illuminant can be estimated. The average angular errors of the illumination spectrum estimation obtained by the proposed method on simulated data and real data are 0.29 and 3.42, respectively. Compared with the existing counterparts, the proposed method shows better accuracy and robustness.

Key words color; multispectral imaging; illuminant spectrum estimation; chroma weight map; dictionary learning; spectral power distribution

1 引言

根据颜色混合的可加性和比例性^[1],彩色成像相机通常采用三个通道(R、G、B)来捕捉物体反射的可见光以进行颜色复现。然而,由于光谱分辨率

低,故 RGB 相机在面对一些需要更多光谱细节的任务时,无法准确区分物体表面的物理特性。多光谱成像技术采用更多通道从场景中捕获更多光谱细节^[2],并通过光源照明标定和光谱反射比重构,使其在高保真颜色复现和许多计算机视觉任务^[3-11](图

收稿日期: 2021-08-27; 修回日期: 2021-09-25; 录用日期: 2021-10-25

通信作者: *chsxu@zju.edu.cn

像分割、模式识别等)中具备极高的应用价值。

由于场景的光谱信息会受不同照明条件的影响,故多光谱成像技术目前仍主要被用于遥感和一些科学实验中。若拍摄场景的光源和照明条件不可控,即光源信息未经标定或测量,则需要先从图像中估计未知的光源信息,这样才能正确重构被摄场景的光谱反射比。因此,准确的照明光源光谱估计对多光谱成像技术在一般照明不可控场景中的应用推广和发展至关重要。

关于多光谱成像技术中的照明估计研究尚少,相关解决方案仍未被深入探索。Ratnasingam 等^[12]在光源不变空间中提取了光源特征并利用伪逆和维纳估计初步还原场景的照明光谱。An 等^[13]利用提取图像中的高光区域估计光源通道响应。Khan 等^[14]将 RGB 图像的一些白平衡算法扩展到多光谱图像中以进行光源通道响应估计。事实上,由于计算复杂度的变化,故许多现有的 RGB 图像白平衡算法^[15-19]并不适用于多通道图像。此外,现有的照明估计研究大多只能预测通道域中的照明光源响应,而不能预测照明光谱。若照明光谱无法估计,则多光谱图像的光谱反射比重构仍将面临巨大挑战。

本文提出了一种基于单幅多光谱图像进行照明光谱估计的通用方法。以单幅未知光源下拍摄的多光谱图像为基础,利用所提方法可在未经光源标定和校准的情况下获得该多光谱图像所对应拍摄场景的光源相对光谱功率分布 (SPD)。在对模拟数据和真实数据的大量实验中,所提方法均表现出了优异的性能。

2 照明光谱估计原理

2.1 多光谱成像模型和光源估计流程

从多光谱成像技术的物理模型出发,在不考虑

各种噪声的情况下,传感器某一像素在可见光波段中所记录的原始响应值可简化表示为

$$f = \int e(\lambda)r(\lambda)s(\lambda)d\lambda, \quad (1)$$

式中: λ 为波长; $e(\lambda)$ 代表场景中照明光源的光谱功率分布函数; $r(\lambda)$ 代表被摄物体的光谱反射比函数; $s(\lambda)$ 代表成像系统在该像素处的响应灵敏度函数。在实际计算中,通常将(1)式描述为向量形式,即

$$\mathbf{F} = (\mathbf{R} \circ \mathbf{E})\mathbf{S}, \quad (2)$$

式中: \mathbf{F} 表示被捕获的多光谱图像; \mathbf{R} 表示被摄物体表面的光谱反射比; \mathbf{E} 代表被捕获场景的照明光源光谱; \mathbf{S} 表示成像系统的光谱灵敏度函数; \circ 表示计算两向量或矩阵的哈达玛积。

由于多光谱图像是一种多通道响应图像,故可将多光谱成像模型在通道层面进行分解。场景照明光谱 \mathbf{E} 在以 \mathbf{S} 为光谱灵敏度函数的成像系统中产生的通道响应 \mathbf{E}_c 可以表示为

$$\mathbf{E}_c = \mathbf{E}\mathbf{S}, \quad (3)$$

与之对应,可将光谱反射比 \mathbf{R} 在成像系统中的通道响应 \mathbf{R}_c 定义为

$$\mathbf{R}_c = \mathbf{R}\mathbf{S}, \quad (4)$$

则(2)式描述的多光谱成像系统可以表示为

$$\mathbf{F} = \mathbf{E}_c \circ \mathbf{R}_c, \quad (5)$$

(2)式和(5)式均表明,在根据多光谱图像 \mathbf{F} 重构场景光谱反射比 \mathbf{R} 中,场景照明光源的相对 SPD 估计至关重要。

图 1 为所提方法的整体框架。首先,通过引入和计算多光谱图像的色度权重图并对图像加权,以有效筛选图像中的有利像素。然后,利用主成分分析法 (PCA) 对加权图像进行光源通道响应特征提取。接着,基于字典学习训练所得的光源光谱字典来恢复光源光谱 \mathbf{E} 。最后,恢复出整个场景的光谱

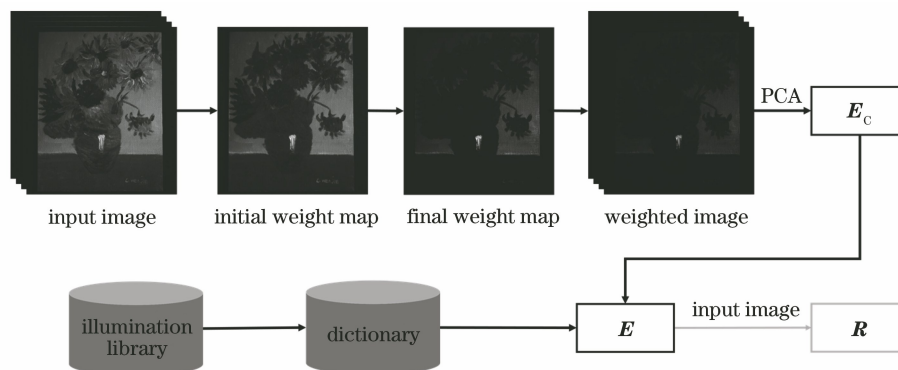


图 1 多光谱图像照明光谱估计方法流程图

Fig. 1 Flow chart of illumination spectrum estimation method for multispectral images

反射比 \mathbf{R} 。详细方法将根据图 1 所示流程分别在下文阐述。

2.2 色度权重图模型

当对传统单幅 RGB 图像进行光源估计时,场景中高彩度材料表面的响应值往往会成为一种较大的干扰,而多光谱图像的通道光源估计中同样存在这样的隐患。由于中性色表面能够全面均匀地反射光源光谱,故为提高单幅图像的照明估计精度,需要减少高彩度表面对应像素的估算权重,并增加场景中中性色表面对应像素的估算权重^[20-21]。RGB 成像很难分辨某个像素点是物体色还是光源色,而多光谱成像具有更窄的通道带宽,其成像光谱分辨率更高。虽然照明光谱各个波段的功率分布可能不同,但是从图像像素的响应值来看,彩度较高的表面对应的像素多个通道响应分布相比近中性色表面总是更加集中。因此,在中性色表面的区分上多光谱图像比传统 RGB 图像具备更大的优势。为此,对多光谱图像的色度权重图进行了定义。对于具有 n 通道响应的单个像素,计算其初始权重 \mathbf{w} 的过程可以表示为

$$\mathbf{w} = \mathbf{C} \mathbf{r}_{\text{sort}}^{\text{T}}, \quad (6)$$

式中: $\mathbf{C} = [q_1 \ q_2 \ \dots \ q_n]$ 代表加权因子; \mathbf{r}_{sort} 代表将该像素点通道响应向量的元素从大到小重新排列后的结果。显然,只要保证 $q_1 < q_2 < \dots < q_n$, 即可使得高彩度表面代表的像素被计算出来的初始权重更低,而让通道能量分布更为平均的近中性色表面对应像素的相对权重更高。由于幂函数形式简单且便于调整权重因子内元素的相对比例,故选用幂函数来构建 \mathbf{C} , 即

$$\mathbf{C} = [x^2(x+2)^2 \ \dots \ (x+2n-2)^2], \quad (7)$$

式中: x 是根据多光谱图像的位深来调整的的大于 1 的参量,预实验表明 x 的变化对所提方法的性能影响不大。对于完整的多光谱图像,其所有像素的初始权重可根据空间位置排列组合成完整的初始色度权重图,记为 \mathbf{W} 。需将初始色度权重图归一化为 \mathbf{W}_N 并重新映射得到最终的色度权重图 \mathbf{W}_F , 以增强该模型在应对不同场景内容时的稳定性,即

$$\mathbf{W}_N = \mathbf{W} / \max(\mathbf{W}), \quad (8)$$

$$\mathbf{W}_F = \varphi(\mathbf{W}_N), \quad (9)$$

式中: $\max(\cdot)$ 为最大值函数; $\varphi(\cdot)$ 为一个分段映射函数,其功能是对原本的归一化权重进行调整,减弱噪声并使高权重像素占据主导地位。 $\varphi(x)$ 可以表示为

$$\varphi(x) = \begin{cases} 0, & x < \delta \\ 1/\{1 + \exp[\kappa(x - 0.5)]\}, & \text{otherwise} \end{cases}, \quad (10)$$

式中: δ 为噪声阈值参数,本文设置为 0.2,映射时低于 0.2 的值将被替换为 0; κ 是用来调整 $\varphi(x)$ 曲线形状的常数参数,本文基于预实验效果较为理想的情况将 κ 设置为 7。

2.3 光源通道响应估计方法

为利用色度权重图来进一步在通道域进行照明光源通道响应的估计,对原始多光谱图像的像素响应值进行加权。将原始图像的每一通道响应图层矩阵分别与权重图矩阵计算哈达玛积,再按照原来的图层顺序组合成加权后的新多光谱图像,即

$$\mathbf{I}_i^{\text{W}} = \mathbf{I}_i \circ \mathbf{W}_F, \quad (11)$$

式中: \mathbf{I}_i 和 \mathbf{I}_i^{W} 分别代表原始多光谱图像和加权后多光谱图像第 i 个通道的响应图层。

加权后的多光谱图像整体减小了高彩度材料表面对应像素的响应值,同时保留并增大了近中性色材料表面对应像素的响应值。由于近中性色表面接近于光谱均匀反射,因此加权图像主要包含的是大量与光源的通道响应特征相近的像素响应值。这些响应值在向量空间中的共同主要特征即为光源通道响应的特征向量。PCA^[22] 非常适合用来在统计上快速找到加权后图像像素样本的主要成分,由于照明光谱估计只考虑相对值,故可将第一主成分作为光源通道响应向量,即

$$\mathbf{E}_C = M_{\text{PCA}}(\mathbf{I}^{\text{W}}), \quad (12)$$

式中: $M_{\text{PCA}}(\cdot)$ 代表第一主成分提取函数。

2.4 光源光谱估计方法

在通道域提取光源响应之后,需要进一步进行光谱细节估计才可以得到照明光源的相对 SPD。由于多光谱系统响应是积分响应,故还原光谱细节非常困难。然而,稀疏表达模型是一种基于学习的特征重构模型,可将待估计的光源光谱表达为有限个已训练得到的基本特征的线性组合。因此,用于训练的光源光谱库 \mathbf{L} 和待估计的光源光谱 \mathbf{E} 均可表示为光源光谱字典 \mathbf{D} 和稀疏系数向量的组合形式,即

$$\mathbf{L} = \mathbf{Q}_L \mathbf{D}, \quad (13)$$

$$\mathbf{E} = \mathbf{Q}_E \mathbf{D}, \quad (14)$$

式中: \mathbf{Q}_L 和 \mathbf{Q}_E 分别对应于照明光谱库和场景光源光谱的稀疏系数向量。为了更直观地与 \mathbf{E}_C 进行关联,在数学上可以定义

$$\mathbf{D}_C = \mathbf{D} \mathbf{S}, \quad (15)$$

此时 D_C 可以代表字典在通道域的形式,故有

$$E_C = Q_E D_S = Q_E D_C. \quad (16)$$

通过构建(16)式所示的稀疏表达模型可知,光源的通道响应可以利用光源光谱字典的通道域形式稀疏表示,并且其稀疏系数向量与在光谱域中的表示相同。因此,为了完整表达已估计得到的光源通道域形式,还需要进行字典学习和稀疏系数向量估计。

根据(13)、(15)式,学习稀疏字典 D 等同于优化

$$\operatorname{argmin}_{D, Q_L} \|L - DQ_L\|_2^2 + \mu \|Q_L\|_0, \quad (17)$$

式中: μ 为优化项权重因子。(17)式所示的稀疏优化问题含有棘手的 l_0 优化项,是一种非凸优化,可利用被广泛应用的 K-SVD 算法^[23-24] 较快地收敛以获得照明光谱字典。

对于稀疏系数向量的估计,根据(16)式可将 Q_E 的优化问题转化为两项凸优化参数估计问题,即

$$\operatorname{argmin}_{Q_E} \frac{1}{2} \|Q_E D_C - E_C\|_2^2 + \gamma \|Q_E\|_1, \quad (18)$$

式中: γ 为优化项权重因子。(18)式所示的问题的优化是极有挑战性的,因为 Q_E 同时存在于两个优化项里。交替方向乘子(ADMM)算法^[25] 是一种应对大规模优化问题的优秀参数优化算法,根据 ADMM 算法的原理,可将(18)式所示问题转化为

$$\operatorname{argmin} \frac{1}{2} \|Q_E D_C - E_C\|_2^2 + \gamma \|Z\|_1 + Y^T(Q_E - Z) + \frac{\rho}{2} \|Q_E - Z\|_2^2, \quad (19)$$

式中: ρ 为优化项权重因子; Y 为引入的拉格朗日乘子; $Z=Q_E$ 为分离等效变量。此外,若 $V=(1/\rho)Y$, 则上述优化问题可通过交替更新 Z 和 Q_E 来迭代求解,即

$$Q_E^{(k+1)} = \operatorname{argmin}_{Q_E} L_p[Q_E, V^{(k+1)}, Z^{(k+1)}], \quad (20)$$

$$Z^{(k+1)} = \operatorname{argmin}_Z L_p[Q_E^{(k+1)}, V^{(k)}, Z], \quad (21)$$

$$V^{(k+1)} = V^{(k)} + Q_E^{(k+1)} - Z^{(k+1)}, \quad (22)$$

式中: k 表示第 k 次迭代计算; $L_p(\cdot)$ 为拉格朗日函数。

为加快迭代速度,求解时通常使用超松弛迭代法^[26-27] 来更新 $Q_E^{(k+1)}$, 即

$$Q_E^{(k+1)} = \alpha Q_E^{(k+1)} + (1 - \alpha) Z^{(k)}, \quad (23)$$

式中: α 为超松弛因子。根据(16)式,可得出(20)式的解,其表达式为

$$Q_E^{(k+1)} = [D_C^T E_C + Z^{(k)} - V^{(k)}] (D_C^T D_C + N)^{-1}, \quad (24)$$

式中: N 是单位对角矩阵。(21)式的求解可用近似

等效的方式来快速计算,即

$$Z^{(k+1)} = \operatorname{sign}[Q_E^{(k+1)} + V^{(k)}] \times \max \left[|Q_E^{(k+1)} + V^{(k)}| - \frac{\gamma}{\rho}, 0 \right], \quad (25)$$

式中: $\operatorname{sign}(\cdot)$ 为符号函数。由于 ADMM 算法较快的收敛速度,因此上述迭代求解过程在实验中的迭代次数不超过 80 次,当 Q_E 不再明显变化时结束迭代。

3 实验与分析

3.1 实验数据

为模拟各种场景在各种照明情况下的多光谱成像过程,根据 2.1 节的多光谱成像模型,在实验中利用光源光谱、各种场景的光谱反射比和成像系统的光谱响应函数,生成不同照明条件下不同场景内容的多光谱图像。然后,以生成的多光谱图像为基础输入,根据所提方法和用于对比的方法来估算光源光谱,并与实际输入的光源光谱比较,以此来验证所提方法的性能。

为全面覆盖真实世界中可能遇到的各种照明光源,本文共计收集整理了 380 种光源光谱功率分布,并将其组建为光源光谱数据库,其中除了包括国际照明委员会(CIE)推荐的各种标准光源外,如 A 光源、B 光源、C 光源、D 系列光源和 F1~F12 系列荧光光源等,还包含了氙灯、等离子灯和白光 LED 等不同光源类型。由于实验中采用的 CAVE 光谱反射比数据库^[28] 波长范围为 400~700 nm,故将这些光源光谱以 10 nm 为间隔裁剪至此波段。实验挑选了具有代表性的 38 种光源作为测试照明光谱,剩余光源光谱作为过完备字典的训练数据。

系统的光谱响应函数包含了多光谱滤色片的光谱透过率函数和光电转换器件的光谱灵敏度函数。后者可视为一种探测器件的固有特性,成像系统的响应函数和滤色片的光谱透过率函数在数学形式上是类似的。虽然现有研究多采用高斯函数来模拟系统光谱响应函数,但是实际工业生产中很难制造出具有如此理想的光谱透过率曲线的滤色片。为了增强实验的可靠性和代表性,本文不失一般性地将一组 8 通道真实多光谱滤色片的透过率曲线等效作为实验的系统响应函数,归一化灵敏度函数如图 2 所示。

DSG 色卡的色块颜色多样性好,在色域中的分布范围广,同时包含了一定数量的人类肤色和不同灰阶的中性色色块,因此适合作为模拟数据的生成基础。采用分光光度计测量 DSG 色卡 140 个色块




图 2 多光谱成像系统的 8 通道光谱灵敏度函数
Fig. 2 8-channel spectral sensitivity function of multispectral imaging system

的光谱反射比函数,其中每个色块测量 3 次并取其平均值。为满足光谱的多样性,随机选取一定数量

的色块,将其光谱反射比向量以随机比例进行线性组合,最终在模拟数据库中生成了多达 40000 组不同的光谱反射比数据。当生成虚拟反射表面时,每次需从数据库中随机选取 400 个光谱反射比样本,生成一幅包含 20×20 个色块表面的虚拟场景。实验共生成 100 个虚拟场景,这样既避免了场景内容过于单一或过于复杂,又保证了实验数据的多样性和普遍性。除此之外,本研究还采用了被广泛使用的 CAVE 多光谱数据库作为真实场景的光谱反射比测试数据,该数据库提供了 400~700 nm 范围内多种真实世界的材料和物体光谱反射比,其中部分场景的彩色示意图如图 3 所示。作为示例,图 4 展示了 CAVE 数据库中一幅油画在 D65 光源下生成的多光谱图像的 8 个图层。




图 3 CAVE 数据库中部分场景的彩色图像
Fig. 3 Color images of partial scenes in CAVE database



图 4 一幅油画的 8 通道多光谱图像
Fig. 4 8-channel multispectral images of oil painting

3.2 评价指标

光源光谱估计的性能评价即是对估算的光谱向量相对真实的光谱向量的偏差进行评估,而角度误

差是描述两个向量在空间中的方向性偏差的重要指标。由于向量之间的量纲并不会影响角度误差的计算结果,而光源估计结果恰好主要关注的是光谱的

相对功率分布估计,故角度误差 A_e 已被广泛用于各种光源估计的评价^[14-19],其表达式为

$$A_e = \arccos \langle \mathbf{E}, \mathbf{E}_{gt} \rangle, \quad (26)$$

式中: \mathbf{E} 和 \mathbf{E}_{gt} 分别代表估计的光源光谱和真实光源光谱。当二者相同时,其角度误差的计算结果便为 0。

3.3 照明光谱估计方法实验结果

为评估所提方法在照明光谱估计上的性能表现,设置了基于模拟数据和真实数据的对比测试实验。综合现有技术研究,大部分已有方法都只停留在照明通道估计,需要利用维纳估计来得到照明光谱并与所提方法比较。用来与所提方法对比的算法包含了多种主流光源通道响应估计算法,包括 white patch (WP)^[29]、grey world (GW)^[30]、grey edge (EG)^[31]、shades of grey (SoG)^[32]、edge weighting (EW)^[33] 和文献 [12] 的 invariant chromaticity space (ICS)。

表 1 为模拟数据构建场景的照明光谱估计角度误差分析,给出了模拟数据库样本在所有 38 种测试光源下的估算角度误差统计,包括误差的平均值、中位数、最小 25% 的平均误差 (Best 25%)、最大 25% 的平均误差 (Worst 25%) 和误差分布标准差 (SD)。其中,加粗数值为最优指标值。由于模拟数据是将色卡的光谱反射比作为基础生成的,且样本点的空间分布完全随机,故有较大概率存在理想的均匀光谱反射比表面,进而各项误差的数值都不大。

表 1 不同光源估计方法基于模拟数据的性能比较

Table 1 Performance comparison of different light source estimation methods based on simulated data

Method	Mean	Median	Best 25%	Worst 25%	SD
WP	1.22	1.28	0.56	1.80	0.49
GW	5.93	6.04	5.12	6.50	0.71
GE	2.36	2.41	2.18	2.69	0.43
SoG	2.52	2.58	1.94	3.00	0.47
EW	1.43	1.47	0.82	1.99	0.46
ICS	3.64	4.12	3.03	5.17	0.62
Proposed	0.29	0.06	0.02	0.37	0.44

从误差平均值来看,所提方法是唯一达到所有场景下平均预测误差小于 0.50 的方法,显著优于其他方法。中位数指标是一项简单却很能表现整体误差水平的数据,可见所提方法在预测误差的中位数方面表现优秀,同时在最小 25% 的平均误差的误差方面也具有优异的表现。值得一提的是,即使对于最大 25% 的平均误差的误差,所提方法依然表现稳定,且远低于其他方法中的最优值(1.80),表明所提

方法在应对各种照明光源和物体色场景时具有良好的鲁棒性。此外,对于误差标准差,各方法的表现相差不大,这可能是因为模拟数据的光谱多样性较高。

真实场景的光源光谱估计性能如表 2 所示。其中,加粗数值为最优指标值。相对较为理想化的模拟数据,真实场景的物体光谱反射比可能更为单一,并且有可能不存在具有均匀光谱反射比的表面,因此算法性能表现会不可避免地出现一定程度的劣化。

表 2 不同光源估计方法基于真实数据的性能比较

Table 2 Performance comparison of different light source estimation methods based on real data

Method	Mean	Median	Best 25%	Worst 25%	SD
WP	6.49	3.37	1.49	16.44	6.72
GW	16.70	16.04	5.66	29.94	9.42
GE	8.52	7.21	2.18	17.57	6.22
SoG	11.74	9.30	2.66	23.29	8.20
EW	12.85	8.10	3.91	25.80	8.93
ICS	13.67	9.3	4.22	24.64	8.05
Proposed	3.42	0.13	0.09	11.62	5.41

由表 2 可知,对于真实场景的光源光谱估计,所提方法依然保持明显优势,平均误差低于 3.50,远小于其他方法中的最低平均误差(6.49)。在误差中位数和误差最小 25% 等的表现,所提方法仍然显著领先,说明所提方法在多数场景下还原的光谱的精度更高。真实场景数据较为复杂,其包括带有多个尖峰的光源光谱,此时的光谱恢复过程中易出现偏差。从误差最大 25% 结果也能看出,虽然各方法都存在一定的照明光谱不可恢复场景,但是所提方法仍表现最好。误差分布的标准差体现了算法在应对各种场景和照明情况时的性能稳定性,可见所提方法具备最佳的鲁棒性。

由于光源光谱的分布细节特征变化范围很大,因此通常不易恢复,尤其对如尖峰的位置和幅度等细节的恢复更为困难,这是因为传感器对光谱积分后,光谱尖峰的特征会被钝化。由于所提方法使用真实光源库进行稀疏学习,故其估计的光谱更符合真实光源可能存在的各种特征。图 5 展示了不同方法对两种具有丰富细节的挑战性光源的光谱估计结果。可以发现,所提的利用光源库进行稀疏学习的方法可以恢复被削减的光谱特征,进而准确地还原这两种照明光谱的尖峰位置及其有效形态。此外,重点关注了 CIE A、D65 和一种光谱细节较为丰富的三基色白光 LED 光源的光谱估计结果,如图 6 所示。其中,括号内的数字表示对应曲线与真实值的




图 5 两种挑战性光源的光谱估计结果。(a)光源 1;(b)光源 2

Fig. 5 Spectral estimation results of two challenging illuminants. (a) Illuminant 1; (b) illuminant 2

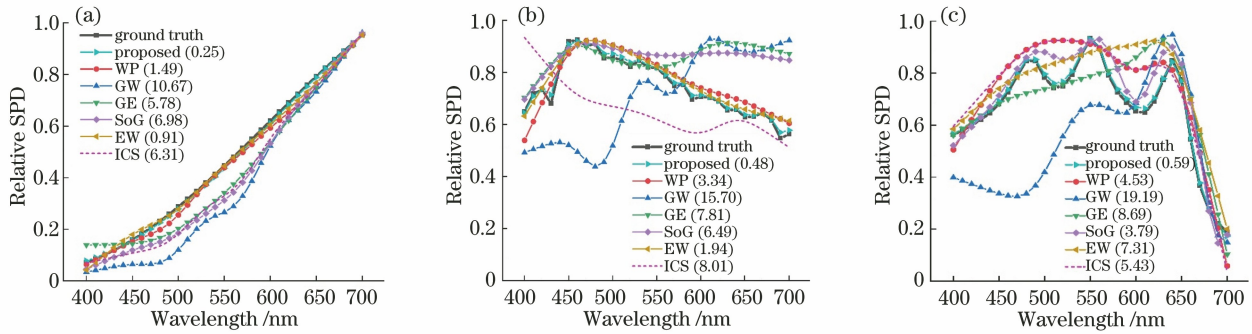


图 6 三种典型照明光源的光谱估计结果。(a) A 光源;(b) D65 光源;(c) LED 光源

Fig. 6 Spectral estimation results of three typical illuminants. (a) Illuminant A; (b) illuminant D65; (c) illuminant LED

角度误差。可以发现,所提方法预测的光源相对 SPD 与真实值最为接近,能够很大程度上还原光谱的细节特征。

3.4 实际测试平台检验结果

为验证所提方法的实际应用性能,搭建了一个实际多光谱成像平台来测试其预测光源光谱的性能。实际测试对象包括了 DSG 标准色卡和图 7 所示的水墨画,测试光源选择了典型的 CIE 标准光源 A、D65 和一种生活中最常见的荧光粉 LED 光源。成像系统为 8 通道的转轮式多光谱相机。基于该平台的测试结果如图 8 所示,图中标注的“GT”、“CC”和“OB”分别表示真实光源光谱、基于色卡估计出的光源光谱和基于水墨画估计出的光源光谱,且均为

相对值。实际测试平台的结果表明了所提方法的应用可行性。

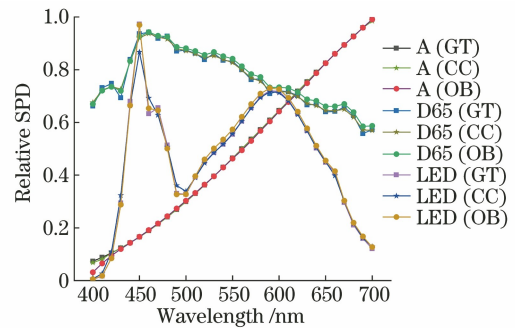


图 8 基于实际测试平台的照明光谱估计结果

Fig. 8 Illumination spectrum estimation results based on real test platform



图 7 水墨画实验样本

Fig. 7 Ink painting used in experiment

4 结 论

针对照明条件不可控场景下捕获的单幅多光谱图像,提出了一种通用方法来估计其场景照明的光谱。根据多光谱成像原理,设计了色度权重图来寻找包含更多照明光源信息的像素。首先,对加权后的单幅多光谱图像进行 CPA,以提取照明光谱在成像系统中的通道响应。然后,引入强力且有效的稀疏字典训练、稀疏系数学习和相关迭代优化方法。

最后,还原出了包含更多细节特征的照明相对 PSD。以角度误差为照明光源光谱估计误差评价标准,各种照明光源下的不同模拟数据和真实数据测试场景的对比实验表明,所提方法在照明光谱估计误差的平均误差、中位数、最小 25% 平均误差、最大 25% 平均值和误差分布标准差方面的表现均明显优于现存同类方法,具备较好的准确性和鲁棒性。

参 考 文 献

- [1] Hunt R W G. The reproduction of colour [M]. Chichester: John Wiley & Sons, Ltd, 2004.
- [2] Hardeberg J Y, Schmitt F, and Brettel H. Multispectral color image capture using a liquid crystal tunable filter[J]. *Optical Engineering*, 2002, 41(10): 2532-2548.
- [3] Liu C, Liu W, Lu X, et al. Application of multispectral imaging to determine quality attributes and ripeness stage in strawberry fruit[J]. *PLoS One*, 2014, 9(2): e87818.
- [4] Xu R, Li C, Paterson A H. Multispectral imaging and unmanned aerial systems for cotton plant phenotyping [J]. *PLoS One*, 2019, 14 (2): e0205083.
- [5] Zhu R F, Ma J Y, Li Z Q, et al. Domestic multispectral image classification based on multilayer perception convolutional neural network [J]. *Acta Optica Sinica*, 2020, 40(15): 1528003.
朱瑞飞, 马经宇, 李竺强, 等. 多层感知卷积神经网络的国产多光谱影像分类[J]. *光学学报*, 2020, 40 (15): 1528003.
- [6] Lai W H, Zhou M R, Hu F, et al. Coal gangue detection based on multi-spectral imaging and improved YOLO v4 [J]. *Acta Optica Sinica*, 2020, 40(24): 2411001.
来文豪, 周孟然, 胡锋, 等. 基于多光谱成像和改进 YOLO v4 的煤矸石检测[J]. *光学学报*, 2020, 40 (24): 2411001.
- [7] Wang W S, Huang M, Li T J, et al. Saliency detection for ship targets on four-band multi-spectral remote sensing images[J]. *Acta Optica Sinica*, 2020, 40(17): 1728001.
王文胜, 黄民, 李天剑, 等. 四波段多光谱遥感图像的船舶目标显著性检测[J]. *光学学报*, 2020, 40 (17): 1728001.
- [8] Cao C P, Wang H Q, Wang K, et al. Intelligent evaluation method of grottoes surface weathering based on multispectral imaging and random forest algorithm[J]. *Acta Optica Sinica*, 2020, 40 (22): 2230001.
曹赤鹏, 王慧琴, 王可, 等. 基于多光谱成像和随机森林算法的石窟表面风化智能评估方法[J]. *光学学报*, 2020, 40(22): 2230001.
- [9] Uemori T, Ito A, Moriuchi Y, et al. Skin-based identification from multispectral image data using CNNs [C] // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 12341-12350.
- [10] Zhi T C, Pires B R, Hebert M, et al. Multispectral imaging for fine-grained recognition of powders on complex backgrounds[C]//*IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 8691-8700.
- [11] Ding H, Chen C, Zhao H C, et al. Smartphone based multispectral imager and its potential for point-of-care testing [J]. *The Analyst*, 2019, 144 (14): 4380-4385.
- [12] Ratnasingam S, Hernández-Andrés J. Illuminant spectrum estimation at a pixel [J]. *Journal of the Optical Society of America A*, 2011, 28 (4): 696-703.
- [13] An D, Suo J, Wang H, et al. Illumination estimation from specular highlight in a multi-spectral image[J]. *Optics Express*, 2015, 23(13): 17008-17023.
- [14] Khan H A, Thomas J B, Hardeberg J Y, et al. Illuminant estimation in multispectral imaging [J]. *Journal of the Optical Society of America A*, 2017, 34(7): 1085-1098.
- [15] Lam E Y. Combining gray world and retinex theory for automatic white balance in digital photography[C]//*Proceedings of the Ninth International Symposium on Consumer Electronics*, June 14-16, 2005, Macao, China. New York: IEEE Press, 2005: 134-139.
- [16] Zhang X S, Gao S B, Li R X, et al. A retinal mechanism inspired color constancy model[J]. *IEEE Transactions on Image Processing*, 2016, 25 (3): 1219-1232.
- [17] Gao S B, Zhang M, Li C Y, et al. Improving color constancy by discounting the variation of camera spectral sensitivity[J]. *Journal of the Optical Society of America A*, 2017, 34(8): 1448-1462.
- [18] Brainard D H, Freeman W T. Bayesian color constancy [J]. *Journal of the Optical Society of America A*, 1997, 14(7): 1393-1411.
- [19] Gao S B, Ren Y Z, Zhang M, et al. Combining bottom-up and top-down visual mechanisms for color constancy under varying illumination [J]. *IEEE Transactions on Image Processing*, 2019, 28 (9): 4387-4400.

- [20] Joze H R V, Drew M S, Finlayson G D, et al. The role of bright pixels in illumination estimation [C]// Color and Imaging Conference, November 12-16, 2012, Los Angeles, California, USA. Springfield: The Society for Imaging Science and Technology, 2012: 41-46.
- [21] Wyszecki G, Stiles W S. Color science [M]. New York: Wiley, 1982.
- [22] Petroni A, Braglia M. Vendor selection using principal component analysis [J]. The Journal of Supply Chain Management, 2000, 36(2): 63-69.
- [23] Aharon M, Elad M, Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [24] Pan Z X, Yu J, Huang H J, et al. Super-resolution based on compressive sensing and structural self-similarity for remote sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(9): 4864-4876.
- [25] Boyd S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. Foundations and Trends® in Machine Learning, 2011, 3(1): 1-122.
- [26] Kincaid D R, Young D M. The modified successive overrelaxation method with fixed parameters [J]. Mathematics of Computation, 1972, 26(119): 705-717.
- [27] Kincaid D R. A class of norms of iterative methods for solving systems of linear equations [J]. Numerische Mathematik, 1972, 20(5): 392-408.
- [28] Yasuma F, Mitsunaga T, Iso D, et al. Generalized assorted pixel camera: postcapture control of resolution, dynamic range, and spectrum [J]. IEEE Transactions on Image Processing, 2010, 19(9): 2241-2253.
- [29] Brainard D H, Wandell B A. Analysis of the retinex theory of color vision [J]. Journal of the Optical Society of America A, 1986, 3(10): 1651-1661.
- [30] Buchsbaum G. A spatial processor model for object colour perception [J]. Journal of the Franklin Institute, 1980, 310(1): 1-26.
- [31] van de Weijer J, Gevers T, Gijsenij A. Edge-based color constancy [J]. IEEE Transactions on Image Processing, 2007, 16(9): 2207-2214.
- [32] Finlayson G D, Trezzi E. Shades of gray and colour constancy [C]//Color and Imaging Conference, November 9-12, 2004, Scottsdale, Arizona, USA. Springfield: The Society for Imaging Science and Technology, 2004: 37-41.
- [33] Gijsenij A, Gevers T, van de Weijer J. Improving color constancy by photometric edge weighting [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(5): 918-929.