

基于自适应加权线性回归的光谱估计方法研究

梁金星^{1,2*}, 胡新荣^{1,2}, 何儒汉^{1,2}, 陈佳^{1,2}

¹ 武汉纺织大学数学与计算机学院, 湖北 武汉 430200;

² 湖北省服装信息化工程技术研究中心, 湖北 武汉 430200

摘要 光谱估计是光谱成像领域的研究热点,提出一种自适应加权线性回归光谱估计方法,首先以线性化的伪逆求解算子为基础,利用齐次多项式对相机数字响应值进行扩展,利用 Tikhonov 正则化方法进行正则化约束,得到全局训练的光谱估计方法,其次依据训练样本对光谱估计精度的影响机理,在求解光谱估计矩阵时进一步引入高斯加权方法,建立自适应加权训练的光谱估计方法,以提高光谱估计精度。利用 28 种数码相机的灵敏度函数构建了仿真成像系统,以 Munsell Matte 颜色样本和 X-rite ColorChecker SG 色卡为实验样本,以光谱均方根误差和色差为评价指标,对本文方法进行了验证。结果表明,新方法在全局训练模式下能取得与现有全局训练方法同等水平的光谱估计精度,且能够克服现有方法存在的曝光敏感性问题;新方法在自适应加权训练模式下,无论是光谱精度还是色度精度,均优于现有方法。

关键词 颜色; 数码相机; 光谱估计; 线性回归; 自适应加权

中图分类号 TP334.2

文献标志码 A

doi: 10.3788/LOP202158.1233001

Research on Spectral Estimation Method Based on Adaptive Weighted Linear Regression

Liang Jinxing^{1,2*}, Hu Xinrong^{1,2}, He Ruhan^{1,2}, Chen Jia^{1,2}

¹ College of Mathematics and Computer Science, Wuhan Textile University, Wuhan, Hubei 430200, China;

² Engineering Research Center of Hubei Province for Clothing Information, Wuhan, Hubei 430200, China

Abstract Spectral estimation has received extensive research in the field of spectral imaging. A spectral estimation method based on adaptive weighted linear regression is proposed. First, a global training model is developed based on pseudo-inverse algorithm, homogeneous polynomial expansion of digital response, and Tikhonov regularization constraint. Second, based on the influence of global training sample on the accuracy of spectral estimation, the adaptive weighted training model is developed to further improve the spectral estimation accuracy by introducing the Gaussian weighted method. The sensitivity functions of 28 digital cameras is used to build a simulation imaging system, the Munsell Matte color sample and the X-rite ColorChecker SG color chart are used as experimental samples, and the metrics of spectral root-mean-square error and color difference are used to evaluate the spectral estimation accuracy. The results show that for the global training model, the new method can achieve almost the same accuracy as the existing methods, and can overcome the exposure sensitivity problems of the existing methods. The new method achieves better results than the existing methods in both spectral accuracy and colorimetric accuracy under the adaptive weighted training model.

Key words color; digital camera; spectral estimation; linear regression; adaptive weighted

OCIS codes 330.7235; 330.1710; 330.1690

收稿日期: 2020-09-25; 修回日期: 2020-10-19; 录用日期: 2020-10-29

基金项目: 湖北省自然科学基金(2020CFB386)、湖北省高等学校优秀中青年科技创新团队计划项目(T201807)、武汉纺织大学科研基金(20200630)

* E-mail: jxliang@wtu.edu.cn

1 引言

光谱是表征物体表面的出射光辐射相对于入射光辐射在各个波段的比值,一方面,其能够反映物体自身对辐射能量的吸收与反射特性,是物体本身物化属性的主要特征之一;另一方面,在可见光范围内,光谱是颜色信息的指纹,依据色度学原理,通过对光源的相对光谱功率分布、光谱和颜色匹配函数进行积分运算,可获得物体表面的颜色信息,因此光谱在诸多领域都发挥着十分重要的作用^[1-6]。

光谱测量是其应用的基础,传统光谱测量设备主要有分光光度计和光谱相机等,通过分光的方式逐波段记录物体表面的光谱数据,虽然这些设备能够实现光谱的准确测量,但分光光度计是单点测量,难以面向细小不规则物体、不可接触或容易产生形变物体应用,光谱相机虽然能够克服基于单点测量方式的局限性,但存在几何精度差、空间分辨率低和系统的应用灵活性差等局限性,而且以上光谱测量设备的价格昂贵,难以实现普适性推广应用。面对传统光谱测量设备的应用局限性,学者们提出了基于数码相机的成像式光谱测量技术,即利用数码相机获取物体表面的数字图像,以数码相机线性化成像模型和病态逆问题求解理论为基础,通过对数码相机进行光谱特性化校正,实现对物体表面光谱的计算测量^[7]。该项技术能够克服传统设备在测量方式上的局限性,实现基于像素级别和高空间分辨率的光谱测量,总体上具有设备廉价、成像快速、使用灵活等特点,而且在计算机视觉、生物医疗、文物保护和环境监测等领域具有重要科学应用价值^[8-12],成为近些年的热点研究方向。

对基于数码相机的光谱测量而言,由低维响应值计算高维光谱数据是病态线性逆问题的求解,现有方法主要采用响应值非线性扩展来提高光谱估计的精度,如文献[13-16]的研究,均采用了非线性多项式扩展回归方法,而 Finlayson 等^[17]的研究表明,基于非线性求解的光谱估计方法具有曝光变化敏感性,导致光谱估计矩阵在不同曝光水平(由曝光时间、感光度等成像参数和光照强度共同决定)下缺乏通用性,限制了方法的实际应用性能。另外,对基于数码相机的光谱测量而言,通常训练样本与测量对象的光谱或色度越接近,光谱测量越准确,但现有大多数方法主要采用全局训练方式对测量对象进行光谱估计,限制了光谱估计的精度,如文献[13-14]的研究,文献[15]提出了基于局部回归的光谱估计方

法,提升了光谱估计的精度,但缺乏对样本的加权处理,文献[16]提出了基于局部训练样本选择和反距离加权的光谱估计方法,但训练样本选择和加权是两个独立的步骤,且缺乏针对不同测量对象应用的自适应性,仍然制约着光谱估计的精度。

针对上述现有研究存在的问题,本文以线性化的伪逆求解算子为基础,利用齐次多项式对相机数字响应值进行扩展,利用 Tikhonov 正则化方法对其进行正则化约束,首先建立基于全局训练模式的光谱估计方法,使之能够保证光谱估计矩阵在不同曝光水平下的单应性,并以此为基础,依据训练样本对光谱估计精度的影响机理,在求解光谱估计矩阵时进一步引入高斯加权方法,得到基于自适应加权训练模式的光谱估计方法,从而确保光谱估计矩阵的自适应求解,提高光谱估计精度。

2 基本原理

2.1 基于数码相机的光谱测量基本原理

数码相机的成像机理如下:自然界场景的反射光场,经过数码相机镜头组聚焦以及初步光学校正之后,再经过红外截止滤光片、微透镜阵列等附着于传感器表面的光学器件,投射到相机传感器上,经过传感器的光电和模数转换,得到初步的 raw 图像,然后再经过一系列的图像信号处理(包括暗电流校正、坏点校正、镜头畸变补偿、黑白场钳制、白平衡校正、去马赛克、颜色空间转换、阶调和反差校正以及一些其他图像增强处理等),最终得到视觉感知满意的彩色图像^[18]。整个成像过程可以分为两个阶段,线性成像阶段和非线性后处理阶段,其中由光场图像到初始 raw 格式图像是线性化成像阶段,图像信号处理中包含的阶调反差调整和其他非线性图像处理,属于非线性后处理阶段。由于不同厂商和不同型号数码相机的后处理所采用的流程算法均有差异,难以用一个简单的类似指数的非线性函数表征,因此现阶段基于数码相机的光谱测量均是以线性化成像模型和 raw 格式响应值为基础开展,本研究亦是如此,其基本原理如下。

基于数码相机的光谱测量以成像的方式对物体表面光谱信息进行记录,假设数码相机的 raw 格式响应值具有良好的线性化响应特性,则数码相机的线性化成像模型可表示为

$$d_i = \int l(\lambda)r(\lambda)t(\lambda)f_i(\lambda)s(\lambda)d\lambda + n_i = \int m_i(\lambda)r(\lambda)d\lambda + n_i, \quad (1)$$

式中： $l(\lambda)$ 为照明光源的光谱分布； $r(\lambda)$ 为物体表面的光谱反射率； $t(\lambda)$ 为数码相机镜头光学器件的总体透射率； $f_i(\lambda)$ 为数码相机第 i 个通道滤光片的透射率； $s(\lambda)$ 为数码相机感光元件光谱灵敏度函数； λ 为波长； $m_i(\lambda)$ 为数码相机第 i 个通道的整体光谱灵敏度函数， $m_i(\lambda) = l(\lambda)t(\lambda)f_i(\lambda)s(\lambda)$ ； d_i 为物体表面第 i 个通道的响应值； n_i 为数码相机第 i 个通道的加性噪声信号。当前的数码相机，无论是采用 CCD 还是 CMOS 等感光元件，其光电转换函数几乎均符合上述光电转换函数的线性化假设^[18]，所生成的 raw 格式图像几乎均为线性化的响应值。在对数码相机系统的噪声进行校正的前提下，通过在可见光谱范围内对(1)式中各个积分参数进行等间隔均匀采样，可将(1)式写为

$$d = M \cdot r, \quad (2)$$

式中： d 为物体表面的响应值向量； M 为包含了 $l(\lambda)$ 、 $t(\lambda)$ 、 $f_i(\lambda)$ 、 $s(\lambda)$ 乘积为一体的相机系统整体灵敏度函数矩阵； r 为物体表面的光谱向量。对基于数码相机的光谱测量而言，目标是以(2)式为基础，建立由低维数字信号 d 到高维光谱信息 r 的光谱估计矩阵 Q ，实现对于任意一个待测量对象的响应值 d_{test} ，均能估计得到其对应光谱数据 r_{test} ，表达式为

$$r_{\text{test}} = Q \cdot d_{\text{test}}, \quad (3)$$

式中： Q 为 M 的逆矩阵； r_{test} 为计算得到的目标光谱向量。当其他成像条件固定时，光谱估计矩阵 Q 的求解直接影响光谱测量的精度。对基于数码相机

光谱测量系统而言，由于系统的通道数通常小于待测量光谱的维度，因此光谱估计矩阵 Q 的求解本质是病态线性逆问题的求解^[7]，病态线性逆问题的求解是工程应用领域的常见问题，相应的求解方法已经发展的比较成熟，当前基于数码相机的光谱测量通常采用伪逆回归法求光谱估计矩阵 Q ，求解形式为

$$Q = R_{\text{train}} \cdot \text{pinv}(D_{\text{train}}), \quad (4)$$

式中： $\text{pinv}()$ 为伪逆运算符号； R_{train} 为训练样本的光谱矩阵； D_{train} 为训练样本的响应值矩阵，本文同样以伪逆法为基础开展光谱估计方法的研究。

2.2 本文光谱估计方法

以基于数码相机的光谱测量原理为基础，针对现有研究存在的不足，本研究提出了一种基于自适应加权线性回归的光谱估计方法，其原理如图 1 所示，以线性化的伪逆求解算子为基础，利用齐次多项式对相机数字响应值进行扩展，利用 Tikhonov 正则化方法对方法进行正则化约束，首先建立基于全局训练模式的光谱估计方法(如图 1 实线所示)，能够保证光谱估计矩阵在不同曝光水平下的单应性，并以此为基础，在数码相机光谱特性和实际测量条件一致或得到校正的前提下，依据训练样本对光谱估计的影响机理，在求解光谱估计矩阵时进一步引入高斯加权方法，得到基于自适应加权训练模式的光谱估计方法(如图 1 整体所示)，从而保证光谱估计矩阵的自适应求解，提高光谱测量的精度，对方法的具体说明如下。

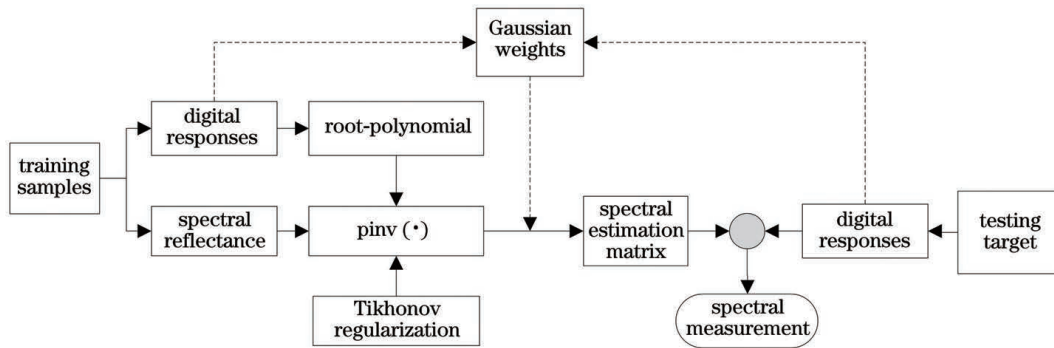


图 1 基于自适应加权线性回归的光谱估计方法流程图

Fig. 1 Flowchart of proposed adaptive weighted linear regression based spectral estimation method

如图 1 中的实线部分所示，在全局训练模式下，首先利用数码相机拍摄获取训练样本和测量对象的 raw 格式数字响应值，并利用分光光度计测量获得训练样本的光谱，然后利用 Finlayson

等^[17]提出的根多项式方法对训练样本和测量对象的数字响应值进行齐次多项式扩展，以常用的三阶多项式为例，其扩展形式共包含 13 个扩展项，即

$$d_{*, \text{exp}} = (r, g, b, \sqrt{rg}, \sqrt{rb}, \sqrt{gb}, \sqrt[3]{r^2g}, \sqrt[3]{r^2b}, \sqrt[3]{rg^2}, \sqrt[3]{rb^2}, \sqrt[3]{gb^2}, \sqrt[3]{g^2b}, \sqrt[3]{rgb})^T, \quad (5)$$

式中: r 、 g 、 b 为训练样本或测量对象 R、G、B 三个通道的数字响应值; $\mathbf{d}_{*, \text{exp}}$ 为经过齐次多项式扩展后的数字响应值向量; 上标“T”表示转置。经过齐次多项式扩展之后, 得到训练样本数字响应值扩展矩阵 $\mathbf{D}_{\text{train, exp}}$, 表示为

$$\mathbf{D}_{\text{train, exp}} = (\mathbf{d}_{\text{train, exp, 1}}, \mathbf{d}_{\text{train, exp, 2}}, \dots, \mathbf{d}_{\text{train, exp, j}})^T, \quad j = 1, 2, \dots, P, \quad (6)$$

式中: j 为第 j 个训练样本; P 为训练样本的数量; $\mathbf{d}_{\text{train, exp, j}}$ 为第 j 个训练样本的数字响应值扩展向量。

如上文所述, 基于数码相机的光谱测量本身是病态逆问题的求解, 求解病态逆问题的常用方法是用一组与原病态逆问题相“邻近”的良态逆问题的解去逼近原问题的解, 称之为正则化约束, 本文利用工程领域中广泛应用的 Tikhonov 正则化对光谱估计矩阵的求解进行正则化约束^[13], 具体求解方法为

$$\mathbf{D}_{\text{train, exp}} = \mathbf{U}\mathbf{S}\mathbf{V}^T, \quad (7)$$

$$\mathbf{P} = \mathbf{S} + \alpha \mathbf{I}, \quad (8)$$

$$\mathbf{D}_{\text{train, exp, rec}} = \mathbf{U}\mathbf{P}\mathbf{V}^T, \quad (9)$$

$$\mathbf{Q} = \mathbf{R}_{\text{train}} \cdot \text{pinv}(\mathbf{D}_{\text{train, exp, rec}}), \quad (10)$$

式中: \mathbf{U} 和 \mathbf{V} 分别为经奇异值分解得到的正交分解矩阵; \mathbf{S} 和 \mathbf{P} 为包含特征值的对角矩阵; \mathbf{I} 为单位矩阵, 通常极小数 α 的值通过测试来确定。首先, 对训练样本的数字响应值扩展矩阵进行奇异值分解, 然后对特征值加上一个极小数 α 得到约束特征值, 以降低数字响应值扩展矩阵的条件数, 并重建得到正则化约束之后的数字响应值扩展矩阵 $\mathbf{D}_{\text{train, exp, rec}}$, 最后求解获得光谱估计矩阵 \mathbf{Q} 。求解获得光谱估计矩阵 \mathbf{Q} 之后, 即可按照(3)式所示形式对任意测量对象进行光谱估计。

此外, 对基于数码相机的光谱测量而言: 1) 训练样本与测量对象的光谱或色度越接近, 光谱估计精度越好, 反之越差; 2) 理论上与测量对象光谱或色度越相似的训练样本应该赋予更大的权重, 与测量对象差别越大的训练样本应赋予较小的权重; 3) 测量对象和训练样本的相似性能够通过二者之间数字响应值的差异性直观地反映出来, 差异性越大时, 二者之间的相似性越低, 反之亦然。基于上述分析, 在上述全局训练模式的基础上, 本文进一步构建了如图 1 所示的基于自适应加权训练模式的光谱估计方法, 具体如下。

首先针对任意一个测量对象, 在求解光谱估计矩阵时, 首先计算测量对象与所有训练样本数字响应值之间的欧氏距离差异 e_j , 即

$$e_j = \sqrt{(r_{\text{test}} - r_j)^2 + (g_{\text{test}} - g_j)^2 + (b_{\text{test}} - b_j)^2}, \quad j = 1, 2, \dots, P, \quad (11)$$

式中: 下标“test”指示测量对象, 并对 e_j 进行最大值归一化处理。

其次, 计算每个训练样本的高斯权重, 即

$$\omega_j = \exp\left(-\frac{e_j}{2k^2}\right), \quad j = 1, 2, \dots, P, \quad (12)$$

式中: k 为确定优化训练样本和调整加权系数的参数^[19], 通过合理的设定调整参数 k , 在计算训练样本权重的同时即可确定局部优化训练样本。

然后, 完成高斯权重矩阵 \mathbf{W} 的构建, 即

$$\mathbf{W} = \begin{bmatrix} \omega_1 & 0 & \dots & 0 \\ 0 & \omega_2 & 0 & \vdots \\ \vdots & 0 & 0 & 0 \\ 0 & \dots & 0 & \omega_P \end{bmatrix}_{P \times P}. \quad (13)$$

接着, 利用训练样本的光谱矩阵 $\mathbf{R}_{\text{train}}$ 、数字响应值扩展矩阵 $\mathbf{D}_{\text{train, exp, rec}}$ 以及权重矩阵 \mathbf{W} , 计算该测量对象的光谱估计矩阵 \mathbf{Q}_{test} , 表示为

$$\mathbf{Q}_{\text{test}} = \mathbf{R}_{\text{train}} \mathbf{W} \cdot \text{pinv}(\mathbf{D}_{\text{train, exp, rec}} \mathbf{W}). \quad (14)$$

最后, 按照(3)式所示形式对测量对象进行光谱估计。需要说明的是, 与采用全局训练模式相比, 采用自适应加权训练模式, 将以时间成本来换取较高的光谱测量精度, 该方法在实际应用时, 可根据具体的应用场景和精度需求进行训练模式的选择。

3 实验

3.1 实验条件

实验利用 Jiang 等^[20]测量得到的 28 种数码相机光谱灵敏度函数的平均值、CIED65 光源、Munsell Matte 颜色样本(简称 Munsell, 1269 个样本)和 X-rite ColorChecker SG 色卡(简称 SG, 140 个样本), 按照(1)式所示的线性化成像模型构建仿真测量系统, 并对仿真数字响应值添加零均值高斯白噪声, 噪声方差为各通道数字响应均值的 0.1%, 以模拟系统难以标定的成像噪声, 系统的光谱灵敏度函数和 CIED65 光源的分布分别如图 2(a) 和图 2(b) 所示。

3.2 实验方法

在上述实验条件下, 本文首先分别以 Munsell 和 SG 作为训练样本估计对方的光谱数据, 对全局训练模式下的光谱测量精度和光谱估计矩阵的曝光变化敏感性进行测试; 其次, 以十折交叉验证方法^[21]为基础对自适应加权训练模式的光谱估计精度进行检验, 并与现有方法进行比较。其中, 十折交

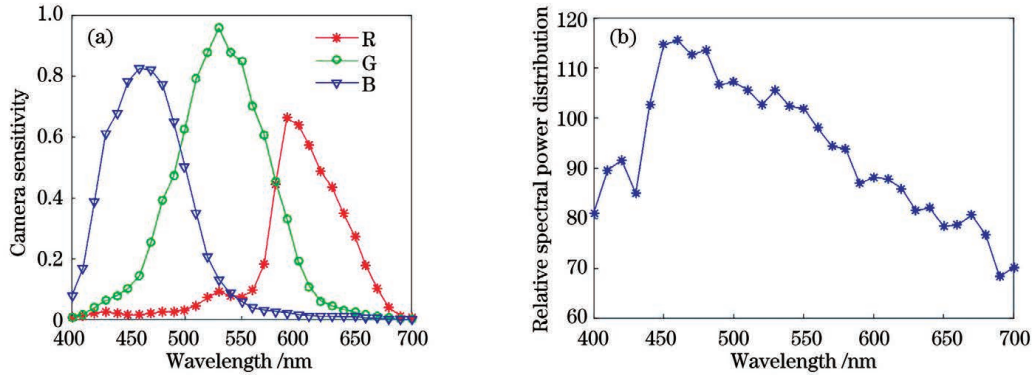


图 2 仿真测量系统。(a)光谱灵敏度函数分布;(b)光源分布

Fig. 2 Simulation measurement system. (a) Spectral sensitivity function distribution; (b) light source distribution

叉验证方法是指将实验样本集随机地近似等分为十份,每次验证时以实验样本集中的九份作为训练样本,剩余一份作为测试样本,直到十份都被测试完为止,最终取十折交叉验证的整体结果对光谱估计方法进行评价和比较。

3.3 评价指标

实验采用光谱均方根误差(RMSE)和 CIED65 光源下的 CIE $L^* a^* b^*$ 色差(ΔE_{ab})作为光谱估计的评价指标,分别从光谱误差和色度误差角度评价本文方法的性能,并与现有方法进行对比,光谱均方根误差和色差 ΔE_{ab}^* 的计算方法为

$$E_{RMSE} = \sqrt{\frac{1}{N}(\mathbf{r}_1 - \mathbf{r}_2)^T(\mathbf{r}_1 - \mathbf{r}_2)}, \quad (15)$$

$$\Delta E_{ab}^* =$$

$$\sqrt{(L_1^* - L_2^*)^2 + (a_1^* - a_2^*)^2 + (b_1^* - b_2^*)^2}, \quad (16)$$

式中: \mathbf{r}_1 为使用本文方法估计得到的光谱向量; \mathbf{r}_2 为与估计光谱对应的真实光谱向量; (L_1^*, a_1^*, b_1^*) 为估计光谱计算得到色度值; (L_2^*, a_2^*, b_2^*) 为真实光谱计算得到的色度值。其中, E_{RMSE} 和 ΔE_{ab}^* 的值越小,表示光谱估计精度越好,反之表示光谱估计精度越差。

表 1 Global 方法与文献[13]方法的平均光谱估计精度比较

Table 1 Average spectral estimation accuracy comparison between Global and Ref. [13] method

Method	Munsell>> SG		SG>> Munsell		
	RMSE / %	ΔE_{ab}	RMSE / %	ΔE_{ab}	
Global	Exposure×1	2.52	0.88	2.14	0.77
	Exposure×0.5	2.52	0.88	2.14	0.77
	Exposure×2	2.52	0.88	2.14	0.77
Ref. [13]	Exposure×1	2.22	0.86	2.14	0.77
	Exposure×0.5	3.19	1.09	3.33	1.01
	Exposure×2	11.96	4.38	6.69	2.94

4 结果与讨论

4.1 全局训练模式光谱估计方法分析

本文首先对全局训练模式光谱估计方法(以 Global 表示)的光谱估计性能进行了测试分析,具体包括光谱估计精度和光谱估计矩阵在不同曝光水平下的应用性能,并且与文献[13]提出的基于非线性多项式扩展的光谱估计方法进行了比较,Global 方法和文献[13]方法均采用三阶扩展形式和 Tikhonov 正则化约束,其中极小值 α 的取值均为 0.001。

表 1 中统计了 Global 和文献[13]两种方法的平均光谱估计精度,其中“>>”符号前为训练样本,符号后为测试样本;“Exposure×1”表示训练样本和测试样本的曝光水平一致;“Exposure×0.5”表示测试样本的曝光水平为训练样本的 0.5 倍,在计算光谱均方根误差和色差 ΔE_{ab} 时,估计得到光谱数据相应地乘以 2;“Exposure×2”表示测试样本的曝光水平为训练样本的 2 倍,在计算光谱均方根误差和色差 ΔE_{ab} 时,估计得到光谱数据相应地乘以 0.5。

由表 1 中的实验结果可知,无论是利用 Munsell 估计 SG,还是利用 SG 估计 Munsell,在训练样本和测试样本的曝光水平一致的情况下 ($\text{Exposure} \times 1$),不管是光谱误差 RMSE 还是色度误差 ΔE_{ab} ,Global 方法和文献[13]方法的光谱估计精度基本无差别,说明基于齐次多项式扩展构建的 Global 方法,能够与基于非线性多项式扩展的文献[13]方法保持同等水平的光谱估计精度。

另外,由表 1 可知,无论测试样本的曝光水平低于 ($\text{Exposure} \times 0.5$) 还是高于 ($\text{Exposure} \times 2$) 训练样本的曝光水平,对基于齐次多项式扩展构建的 Global 方法而言,其估计得到的光谱数据经过曝光校正之后,与 $\text{Exposure} \times 1$ 条件下的光谱估计精度完全一致,而基于非线性多项式扩展的文献[13]方法则不具有此特性,其光谱估计误差随着曝光水平

的变化有不同程度的增加。这说明了 Global 方法的光谱估计矩阵对于曝光水平的变化具有单应性,即不同曝光水平下估计得到的光谱曲线之间具有线性映射(平行)关系,从而保证特定曝光水平下求解的光谱估计矩阵在不同曝光水平下的普适性应用,而基于非线性多项式扩展的光谱估计方法,由于其非线性外插特性^[17],导致其在特定曝光水平下求解的光谱估计矩阵丢失了面向不同曝光水平应用的单应性,从而引起较大的光谱测量误差。

为更加直观地对光谱估计矩阵的单应性问题进行说明,图 3 和图 4 展示了 Munsell 作为训练样本、SG 作为测试样本时,在 $\text{Exposure} \times 1$ 、 $\text{Exposure} \times 0.5$ 和 $\text{Exposure} \times 2$ 三组实验条件下,SG 色卡的 I3 号样本分别在 Global 和文献[13]两种方法下的光谱估计结果分布情况。

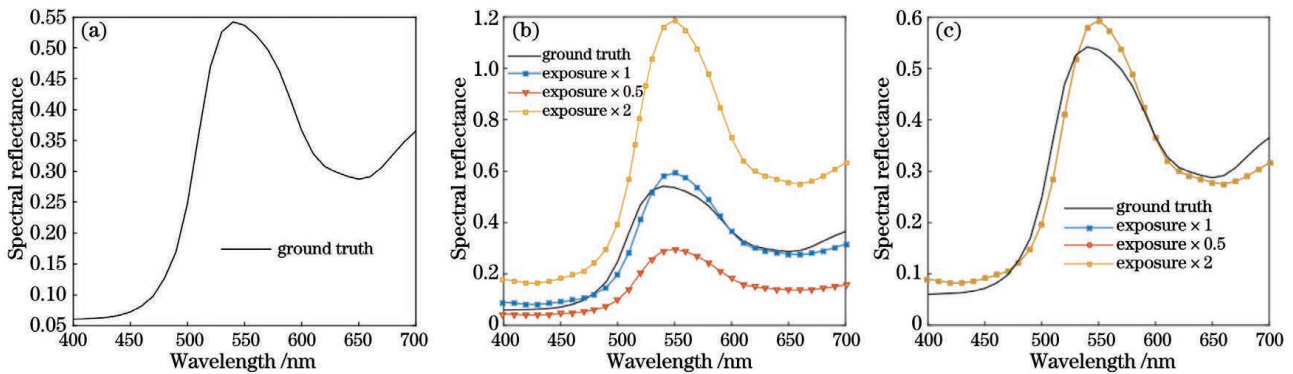


图 3 SG 色卡的 I3 号样本利用 Global 方法进行光谱估计的结果。(a)真实光谱;(b)未经曝光校正的估计光谱;(c)经过曝光校正的估计光谱

Fig. 3 Spectral estimation results of sample I3 in SG chart using Global method. (a) Ground truth; (b) estimated spectral without exposure correction; (c) estimated spectral after exposure correction




图 4 SG 色卡的 I3 号样本利用文献[13]方法进行光谱估计的结果。(a)真实光谱;(b)未经曝光校正的估计光谱;(c)经过曝光校正的估计光谱

Fig. 4 Spectral estimation results of sample I3 in SG chart using Ref. [13] method. (a) Ground truth; (b) estimated spectral without exposure correction; (c) estimated spectral after exposure correction

对比图 3 和图 4 中的实验结果可知,对于 Global 方法而言,其光谱估计矩阵在不同曝光水平

下估计得到的光谱曲线之间完全平行,如图 3(b)所示,经过曝光校正之后的光谱曲线完全重合,如

图 3(c)所示,其各自与真实测量光谱之间的误差一致;但是对于文献[13]方法而言,相对于 Exposure \times 1 条件下的结果,其在 Exposure \times 0.5 和 Exposure \times 2 条件下估计的光谱曲线形状发生改变,如图 4(b)所示,从而导致经曝光校正后的估计光谱与真实测量光谱之间存在较大差异,如图 4(c)所示。上述实验结果体现了基于齐次多项式扩展光谱估计方法的优越性,在面向大幅面和光照不均匀环境下的光谱测量分析应用中,Global 方法能够有效克服现有方法对于曝光水平变化的敏感性,确保同一物体在不同照度下的光谱曲线形状一致性,保持测量对象所固有的光谱曲线形状特征,为基于光谱特征的物化属性分析应用提供保障。

4.2 自适应加权训练模式光谱估计方法分析

本文进一步对自适应加权训练模式光谱估计方法(以 Proposed 表示)的光谱估计精度进行了检验,并与现有的几种常用方法进行了比较。本文分别以 Munsell 颜色样本和 SG 色卡各自作为测试样本,采用十折交叉验证方法,对各方法进行测试,其中 Tikhonov 正则化约束参数同样取值为 0.001。对于本文基于自适应加权训练模式的光谱估计方法而言,经实验测试,在十折交叉验证中,Munsell 颜色样本和 SG 色卡的加权调整参数 k 分别取 0.15 和 0.23 时,可以获得最优的光谱估计精度,因此本部分以 $k=0.15$ 和 $k=0.23$ 作为 Munsell 颜色样本和 SG 色卡光谱估计的最优加权参数,并与文献[13-16]方法进行了比较,光谱估计结果如表 2 所示。

表 2 本文方法与现有几种常用方法的平均光谱估计精度比较

Table 2 Average spectral estimation accuracy comparison between proposed method and several common methods

Method	Munsell		SG	
	RMSE / %	ΔE_{ab}	RMSE / %	ΔE_{ab}
Ref. [13]	1.45	0.63	1.98	0.74
Ref. [14]	1.46	0.64	1.99	0.76
Ref. [15]	1.14	0.49	2.03	0.76
Ref. [16]	0.89	0.47	1.61	0.67
Proposed	0.81	0.35	1.49	0.53

由表 2 中的实验结果可知,对 Munsell 颜色样本而言,本文方法的光谱均方根误差为 0.81,色差为 0.35,相对于文献[13]和文献[14]两种方法,光谱估计误差分别降低了约 0.64 和 0.28,光谱估计

精度提高 40% 以上;相对于文献[15]和文献[16]两种优化方法而言,光谱均方根误差和色差也有明显的降低。对于 SG 色卡而言,本文方法的光谱均方根误差为 1.49,色差为 0.53,相对于文献[13]和文献[14]两种方法,光谱估计误差分别降低了约 0.49 和 0.21,光谱估计精度提高 25% 以上;相对于文献[15]和文献[16]两种优化方法而言,光谱均方根误差和色差同样也有明显的降低。总体而言,无论是 Munsell 颜色样本还是 SG 色卡,本文基于自适应加权训练模式光谱估计方法的精度均显著优于现有的几种常用方法。

5 结 论

基于数码相机的光谱测量技术在诸多光谱分析领域具有广阔的应用前景和研究价值,本研究针对现有光谱估计方法采用非线性多项式扩展所存在的曝光敏感性问题,提出了基于齐次多项式扩展的光谱估计方法,有效解决了光谱估计矩阵对曝光变化的敏感性,保证了光谱估计矩阵在不同曝光水平下应用的单应性,并在此基础上进一步依据训练样本对光谱估计的影响机理,提出了基于自适应加权训练的光谱估计新方法,有效地解决了现有方法对训练样本处理的不足,提高了光谱估计的精度,并通过仿真数码成像系统对本文方法的有效性和优越性进行了验证,为基于数码相机的光谱测量分析应用提供了方法支撑。

参 考 文 献

- [1] Aizu Y, Maeda T, Kuwahara T, et al. Skin image reconstruction using Monte Carlo based color generation[J]. Proceedings of SPIE, 2010, 7851: 78510N.
- [2] Kim T, Visbal-Onufrak M A, Konger R L, et al. Data-driven imaging of tissue inflammation using RGB-based hyperspectral reconstruction toward personal monitoring of dermatologic health[J]. Biomedical Optics Express, 2017, 8(11): 5282-5296.
- [3] Grabowski B, Masarczyk W, Głomb P, et al. Automatic pigment identification from hyperspectral data[J]. Journal of Cultural Heritage, 2018, 31: 1-12.
- [4] Yang Y R, Bu Y, Xu J H, et al. Measurement of surface defects of optical elements based on spectral estimation and multispectral technique [J]. Chinese Journal of Lasers, 2019, 46(9): 0904002.

- 杨言若, 步扬, 徐静浩, 等. 基于光谱估计与多光谱技术的光学元件表面疵病检测[J]. 中国激光, 2019, 46(9): 0904002.
- [5] Wang Y N, Zhu D N, Wang H Q, et al. Multispectral image classification of mural pigments based on convolutional neural network[J]. *Laser & Optoelectronics Progress*, 2019, 56(22): 221001.
王燕妮, 朱丹娜, 王慧琴, 等. 基于卷积神经网络的壁画颜料多光谱图像分类[J]. *激光与光电子学进展*, 2019, 56(22): 221001.
- [6] Yang L, Wang H Q, Wang K, et al. Spectral information unmixing of mixed pigment based on clustering optimization FastICA algorithm[J]. *Acta Optica Sinica*, 2020, 40(5): 0530001.
杨蕾, 王慧琴, 王可, 等. 基于聚类优化 FastICA 的混合颜料光谱信息解混算法[J]. *光学学报*, 2020, 40(5): 0530001.
- [7] Ribes A, Schmitt F. Linear inverse problems in imaging [J]. *IEEE Signal Processing Magazine*, 2008, 25(4): 84-99.
- [8] Li Y Q, Wang C, Zhao J Y. Locally linear embedded sparse coding for spectral reconstruction from RGB images[J]. *IEEE Signal Processing Letters*, 2018, 25(3): 363-367.
- [9] Rueda H, Lau D, Arce G R. Multi-spectral compressive snapshot imaging using RGB image sensors[J]. *Optics Express*, 2015, 23(9): 12207-12221.
- [10] Toque J A, Murayama Y, Ide-Ektessabi A. Pigment identification based on spectral reflectance reconstructed from RGB images for cultural heritage investigations[J]. *Proceedings of SPIE*, 2010, 7531: 75310K.
- [11] Blasinski H, Breneman J, Farrell J. A model for estimating spectral properties of water from RGB images[C]//2014 IEEE International Conference on Image Processing (ICIP), October 27-30, 2014, Paris, France. New York: IEEE Press, 2014: 610-614.
- [12] Kim T H. Hyperspectral image reconstruction from RGB data and its biomedical applications [D]. Purdue: Purdue University, 2017: 115-132.
- [13] Connah D R, Hardeberg J Y. Spectral recovery using polynomial models[J]. *Proceedings of SPIE*, 2005, 5667: 65-75.
- [14] Xiao K D, Zhu Y T, Li C J, et al. Improved method for skin reflectance reconstruction from camera images[J]. *Optics Express*, 2016, 24(13): 14934-14950.
- [15] Zhang X D, Wang Q, Li J C, et al. Estimating spectral reflectance from camera responses based on CIE XYZ tristimulus values under multi-illuminants [J]. *Color Research & Application*, 2017, 42(1): 68-77.
- [16] Liang J X, Wan X X. Optimized method for spectral reflectance reconstruction from camera responses[J]. *Optics Express*, 2017, 25(23): 28273.
- [17] Finlayson G D, Mackiewicz M, Hurlbert A. Color correction using root-polynomial regression[J]. *IEEE Transactions on Image Processing*, 2015, 24(5): 1460-1470.
- [18] Nakamura J. Image sensors and signal processing for digital still cameras [M]. Boca Raton: CRC Press Inc., 2005: 78-84.
- [19] Harrington P. Machine learning in action [M]. Greenwich: Manning Publications Co., 2012: 160-162.
- [20] Jiang J, Liu D Y, Gu J W, et al. What is the space of spectral sensitivity functions for digital color cameras?[C]//2013 IEEE Workshop on Applications of Computer Vision (WACV), January 15-17, 2013, Clearwater Beach, FL, USA. New York: IEEE Press, 2013: 168-179.
- [21] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection [C] // International Joint Conference on Artificial Intelligence, August, 1995, San Francisco, CA, United States. San Francisco: Morgan Kaufmann Publishers Inc., 1995.