

基于自编码器的显微图像色彩恒常算法

蓝方鸣¹, 彭宗举^{1,2*}, 陆志华¹, 史启超¹, 陈芬²

¹ 宁波大学信息科学与工程学院, 浙江 宁波 315201;

² 重庆理工大学电气与电子学院, 重庆 400054

摘要 针对显微图像领域色彩恒常(CC)数据集缺乏、CC算法跨数据集训练效果不佳的问题,通过相机采集和模拟生成两个步骤建立了显微CC数据集,并提出了一种基于自编码器的显微图像CC算法。该算法用改进的UNet结构自编码器进行半监督训练,同时引入一种新的复合损失函数优化网络参数,使恢复的图像色彩更准确。实验结果表明,相比传统自编码器,本算法训练的图像清晰度更高,在NUS-8 CC数据集、RECommended CC数据集和自建显微CC数据集中的角误差估计值更小。

关键词 图像处理; 显微图像; 色彩恒常; 自编码器; 角误差估计

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.2010010

Color Constancy Algorithm of Microscopic Images Based on Autoencoder

Lan Fangming¹, Peng Zongju^{1,2*}, Lu Zhihua¹, Shi Qichao¹, Chen Fen²

¹ Faculty of Information Science and Engineering, Ningbo University, Ningbo, Zhejiang 315201, China;

² School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China

Abstract Considering the lack of color constancy (CC) dataset in the field of microscopic images and the failure in achieving the expected effect through the cross-dataset training of the CC algorithm, this study creates a microscopic CC dataset using two steps: camera acquisition and simulation generation. Moreover, this study proposes a microscopic image CC algorithm based on an autoencoder. The algorithm uses an improved UNet structure autoencoder for semi-supervised training and simultaneously introduces a new composite-loss function to optimize network parameters, thereby obtaining an accurate restored image color. Experimental results show that the image resolution trained using the algorithm is higher than traditional autoencoders, and the angle error estimates in the NUS-8, RECommended, and self-built microscope CC datasets are smaller.

Key words image processing; microscopic image; color constancy; autoencoder; angle error estimates

OCIS codes 100.2000; 100.3020

1 引言

显微图像^[1-2]在显微世界探索和医学研究等方面扮演着重要的角色。和人类视觉感知系统不同,显微镜相机不能自动适应不同光源的变化,获取的图像不能很好地保持拍摄对象的真实色彩。显微图

像的色彩恒常(CC)指的是对采集的显微图像进行处理,将其颜色还原为拍摄对象的真实色彩^[3-4]。CC有利于显微图像的特征检测、目标跟踪、图像分割^[5]和三维重建^[6-7]。相比传统的数字相机,显微镜相机的成像范围较小,无法参照标准色卡。因此,显微图像的色彩恒常(CC)具有较大的挑战性。

收稿日期: 2020-11-16; 修回日期: 2020-12-28; 录用日期: 2021-01-06

基金项目: 浙江省自然科学基金(LY20F010005)、重庆市教委科学技术研究项目(KJZD-K202001105)、重庆理工大学科研启动基金(2020ZDZ029, 2020ZDZ030)

通信作者: *pengzongju@126.com

数字图像 CC 算法通过模拟人类的视觉系统达到色彩还原目的,可以分为基于统计学假设^[8-11]和基于深度学习^[12-18]两大类。CC 算法的关键是对光源进行准确估计。Buchsbaum^[8]提出灰度世界(GW)算法,该算法假设自然景物对光线的平均反射是个定值,反射光近似为灰色。Land 等^[9]假设光源颜色为图像中白色块反射出的颜色,提出了白块(WP)算法。Elisabetta^[10]提出了灰度梯度(SoG)算法,其实质是高阶范数下的 GW 算法。van de Weijer 等^[11]提出灰度边缘(GE)算法,提取图像边缘中若干个点作为光反射点来估计光源,再进行色彩校正。上述基于统计学假设的传统 CC 算法处理结果不够理想,色彩恢复误差较大。Cheng 等^[12]提出了一种基于主成分分析(PCA)的 CC 算法,能快速恢复偏色图像,但该算法在单一色彩场景中恢复的图像色彩比较单一,在显微场景中的处理效果不理想。Bianco 等^[13-14]提出了一种基于卷积神经网络(CNN)的 CC 算法,针对该算法依赖网络预训练结果且泛化性不强的问题,进一步提出了一种无监督的基于灰度图提取白点的白平衡(WB)算法,该算法比较依赖图像灰度化后提取的白点区域,在 CC 数据集中的平均误差较小,但在跨数据集中的色彩恢复结果存在较大误差。Afifi 等^[15]提出了一种基于多偏色场景学习的 CC 算法,能很好地还原不同光源场景的偏色图像,但在显微图像数据集中进行跨库训练的效果较差。Gong^[16]提出的基于卷积均值的 CC 算法和 Hernandez-Juarez 等^[17]提出的多假设 CC 算法在处理速度和算法稳定性等方面有一定优势,但色彩恢复的整体误差还有一定的提升空间。Das 等^[18]提出了三种基于生成式对抗网络(GAN)的 CC 算法,其泛化性较强,但该算法的损失函数未考虑局部色彩,色彩恢复误差较大。

综上所述,传统基于统计学假设的 CC 算法容易导致复原后图像的色彩饱和度偏低,而基于学习的算法比较依赖预训练结果,跨数据集训练效果不佳。针对这些算法在显微图像领域 CC 的不足,本文提出了一种半监督的基于 UNet 结构^[19]自编码器的显微图像 CC 算法,并通过实验验证了该算法的可行性。

2 数据集的建立

基于深度学习的 CC 算法需要大量的数据作为训练支撑,基于统计学假设的 CC 算法则需要大量的数据进行可靠性检验。目前,相关领域还没有专

门针对显微图像的 CC 数据集,因此,构建了一个数据集,包含 297 组显微相机采集到的真实输出图像(GT)和 RAW 图像(CMOS 或 CCD 图像传感器将捕捉到的光源信号转化为数字信号的原始数据)以及 10872 组在 Kaggle 癌症细胞检测挑战数据集^[20]中收集的显微图像 GT 和模拟生成的 RAW 图像。

2.1 采集数据集

常规显微镜的光源色温范围为 2800~7000 K,光源色温不同,相机原始图像的偏色也不同。因此,在色温为 4500,6300,7000 K 的光源下,对 100 种标本装片分别采集了 100 组、98 组和 99 组(共 297 组)有效 RAW 图像对的白平衡图像以及相机真实图像,如图 1 所示。

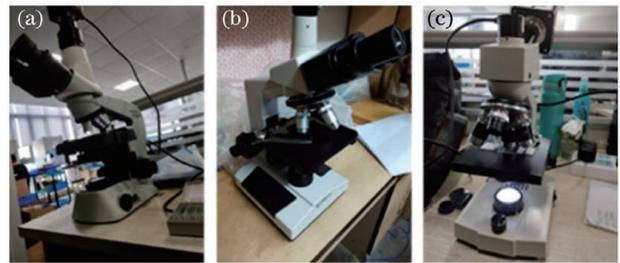


图 1 显微镜及相机的实物图。(a)色温为 4500 K;
(b)色温为 6300 K;(c)色温为 7000 K

Fig. 1 Physical image of the microscope and camera.
(a) Color temperature is 4500 K; (b) color temperature is 6300 K; (c) color temperature is 7000 K

2.2 模拟生成数据集

假定 I_c 为相机输入的 RAW 图像, $c \in \{R, G, B\}$ 为图像红、绿、蓝三颜色通道。一般情况下,经过相机的 WB 处理、色彩矩阵(CCM)校正和伽马校正共同作用后可得到输出图像 I_c'' 。首先, I_c 经过偏色校正后得到白平衡图像 I_c' , 可表示为

$$I_c' = I_c \times g_c, \quad (1)$$

式中, g_c 为白平衡校正系数。然后,在色彩矩阵的作用下,得到色彩校正图像 I_c'' , 可表示为

$$I_c'' = M \times I_c', \quad (2)$$

式中, M 为 3×3 色彩矩阵(一般为固定值)。最后,色彩校正图像 I_c'' 经过伽马校正后得到 GT 图像 I_c''' , 可表示为

$$I_c''' = I_c''^\gamma, \quad (3)$$

式中, γ 为伽马值,实验取为 2.2。

将偏色系数定义为 RAW 图像与白平衡图像的比值,计算不同显微镜采集的图像数据偏色系数并统计成散点图,结果如图 2 所示。其中,横坐标为当

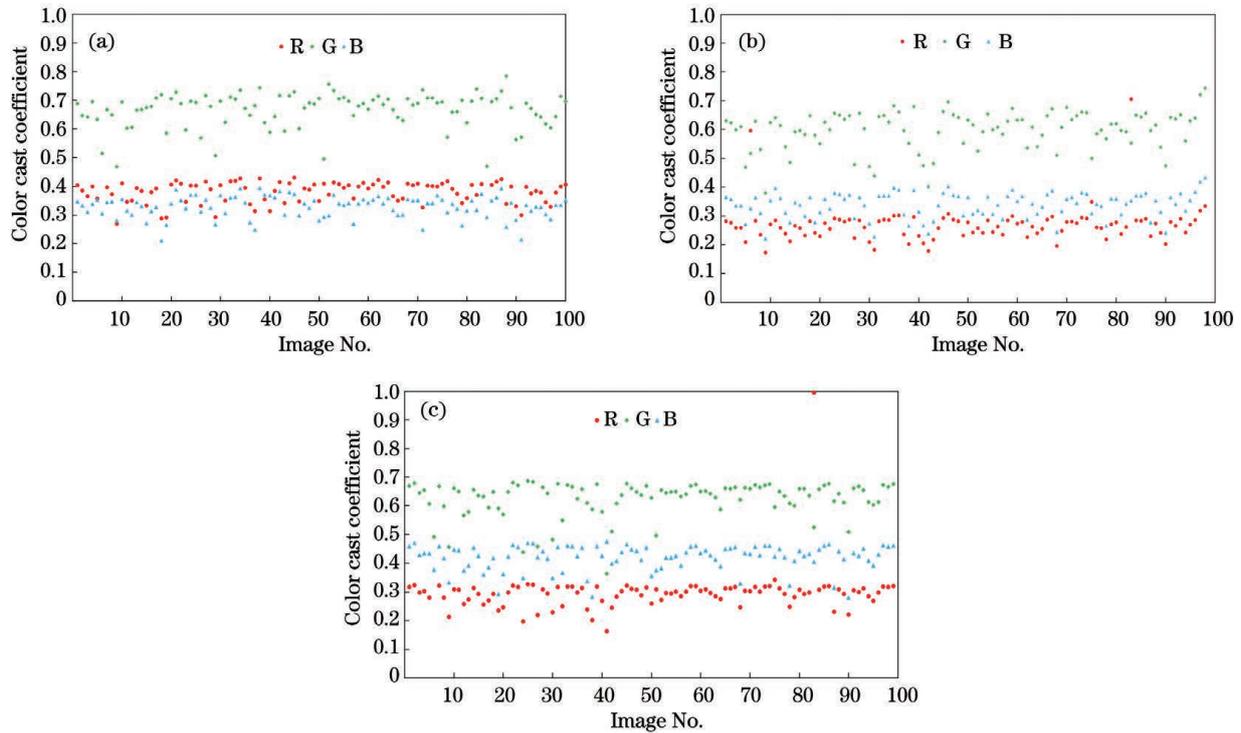


图 2 偏色系数的统计。(a)色温为 4500 K;(b)色温为 6300 K;(c)色温为 7000 K

Fig. 2 Statistics of the color cast coefficient. (a) Color temperature is 4500 K; (b) color temperature is 6300 K; (c) color temperature is 7000 K

前样本的标号,纵坐标为偏色系数。可以发现,不同色温光源下获取的 RAW 图像红色通道和蓝色通道的偏色系数较小,而绿色通道偏色系数较大,因此,RAW 图像大部分呈绿色。而个别样本的 RAW 图像和白平衡图像红色通道值比较接近,计算的偏色系数较大,即图中偏差较大的点。

为了更准确地模拟出偏色 RAW 图像,用 NUS-8^[21] 和 RECommended^[22] 两个 CC 数据集中 10 款相

机、2304 组图像提供的偏色系数,与图 2 中统计的 297 组显微图像偏色系数共同组成一个更稳定的模拟偏色系数组。收集的 10872 张显微图像中的一张如图 3(a)所示,将该图像根据(3)式进行伽马校正,得到 CCM 图像,如图 3(b)所示。按(2)式进行色彩校正得到 WB 图像,如图 3(c)所示。最后,将统计的 2601 组偏色系数随机并循环后经偏色运算作用于 WB 图像,得到模拟的 RAW 图像,如图 3(d)所示。

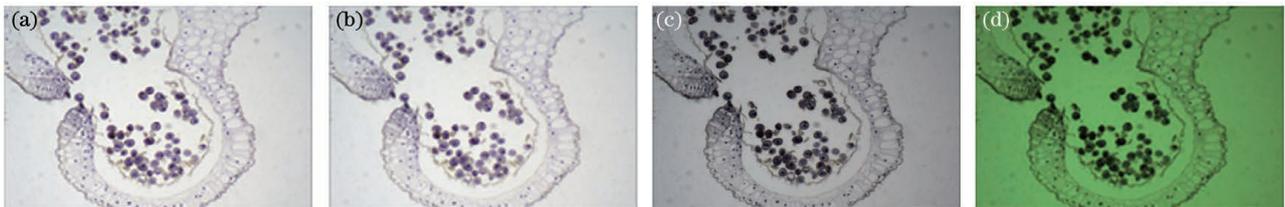


图 3 模拟生成的 RAW 图像。(a)GT;(b)CCM;(c)WB;(d)RAW

Fig. 3 RAW image generated by simulation. (a) GT; (b) CCM; (c) WB; (d) RAW

3 算法描述

场景图像是由相机经过一个或多个光源照明辅助得到,在计算机视觉中相机捕获的场景光照物理模型可被描述为

$$\rho_c(X) = \int E(\lambda) S(\lambda, X) C_c(\lambda) d\lambda, \quad (4)$$

式中, $\rho_c(X)$ 为通道 c 相机传感器获取的像素 X 位

置的光照强度, λ 为光波长, $E(\lambda)$ 为相机接收到的光源光谱值, $S(\lambda, X)$ 为像素 X 处的物体表面光反射值, $C_c(\lambda)$ 为相机的光灵敏度^[23]。图像 CC 的关键是图像全局光照色彩 ρ_c^E 的估计,可表示为

$$\rho_c^E = \int E(\lambda) C_c(\lambda) d\lambda. \quad (5)$$

图像存在无穷多个表面反射值和光源光谱值的组合,即不同相邻像素存在光照均匀的情况,对

应的局部光照估计结果也相同;非相邻像素之间的光照估计存在差异,导致全局光照估计具有不确定性。

3.1 改进的 UNet 结构自编码器网络

目前,基于深度学习的训练方法在一定程度上能较好地解决全局光照估计的不确定性问题,但依然存在处理速度慢或对预训练模型依赖性较强等缺点。无监督的卷积自编码器可以避免过拟合和摆脱对预训练网络的依赖,可适用于其他未训练的数据库。因此,用一个卷积自编码器网络训练没有标签的偏色显微数据集,可以有效减小不同相机偏色系数和场景对光照估计的影响。但用普通编解码网络的自编码器训练时会导致输出图像数据受到压缩,产生图像失真等问题,如图 4 所示。为了得到更好的色彩恢复效果,本算法对传统卷积自编解码网络结构进行了改进。

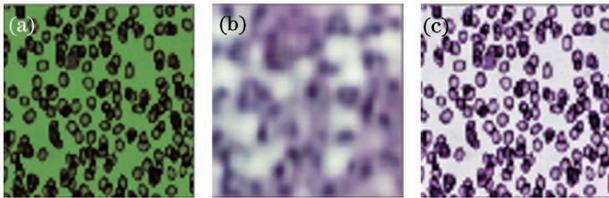


图 4 不同自编码器的色彩恢复结果。(a)原始图像;
(b)自编码器;(c)UNet 自编码器

Fig. 4 Color restoration results of different autoencoders.
(a) Original image; (b) autoencoder; (c) UNet autoencoder

本算法采用 UNet 结构的自编码器网络,该网络包含卷积层、池化层、跳跃连接层以及随机失活层。编码器通过卷积和池化等方式降低输出特征图的空间分辨率,解码器负责修复图像的色彩并提升特征图的空间分辨率。编码器与解码器之间存在跳跃式连接,恢复出的特征图融合了图像的低层特征和全局特征,以确保最终恢复图像中物体的细节更精细。经典的 UNet 在编码部分采用 3×3 卷积层和 2×2 池化层。由于单一的卷积操作往往很难学习到不同尺度特征图像细节部分的色彩信息,同时也会限制训练网络的宽度和深度。因此,采用 Inception 结构卷积替代传统的卷积操作,通过 1×1 、 1×3 、 3×1 、 5×5 、 1×7 和 7×1 等卷积核的组合,在减少模型参数数量的同时加深网络的层数,从而提升图像细节部分的色彩恢复能力。该网络的具体结构如图 5 所示,其中,Conv 为卷积操作。

改进后的 UNet 结构自编码器网络如图 6 所示,其中最左侧为当前数据。编码端卷积滤波器的

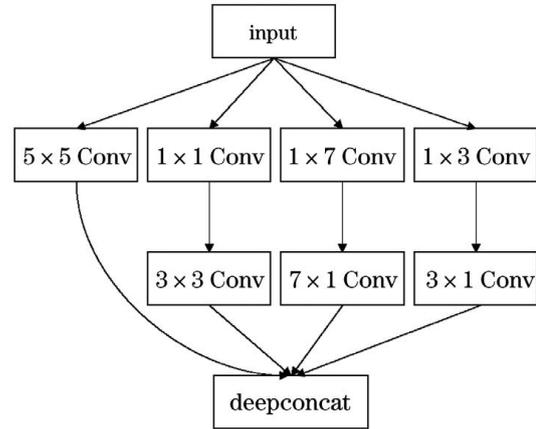


图 5 Inception 的结构

Fig. 5 Structure of the Inception

第一层到第四层 Inception 结构卷积的深度分别为 64、128、256、512,中间段选择深度为 1024 的 Inception 结构卷积,这些卷积滤波器均作用于每层三个图块之间。解码端与编码端对称,但加入了跳跃连接层,其中,解码端第一层与编码端第四层相连,解码端第二层与编码端第三层相连,解码端第三层与编码端第二层相连,解码端第四层与编码端第一层相连,每层均采用线性整流单元(ReLU)激活函数,目的是克服可能产生的梯度消失情况、提高模型的泛化能力并减少参数量。优化算法选择收敛速度较快的 Adam 算法。

3.2 损失函数

为使本算法建立的 UNet 自编码器得到更好的训练,定义了一种新的损失函数进行网络参数优化。该复合损失函数分为两部分:第一部分使用交叉熵损失函数对标签数据和没有标签的数据进行训练,以学习图像数据的全局信息;第二部分用场景光照与真实光照误差作为损失函数,对图像数据场景的光照进行估计。将上述两部分进行融合得到一个半监督的自编码网络复合损失函数,可表示为

$$L_{\text{loss}}(C) = \alpha \times \frac{1}{|C|} \sum_{x \in C} L_{\text{cross}}(x, \tilde{x}) + (1 - \alpha) \times \frac{1}{|C|} \sum_{x \in C} L_{\text{angle}}(\boldsymbol{\rho}^{\text{GT}}, \boldsymbol{\rho}^*) / T, \quad (6)$$

$$L_{\text{angle}}(\boldsymbol{\rho}^{\text{GT}}, \boldsymbol{\rho}^*) = \arccos\left(\frac{\boldsymbol{\rho}^{\text{GT}} \cdot \boldsymbol{\rho}^*}{\|\boldsymbol{\rho}^{\text{GT}}\| \|\boldsymbol{\rho}^*\|}\right), \quad (7)$$

式中, C 为训练数据集, $L_{\text{cross}}(x, \tilde{x})$ 为交叉熵函数, x 为真实图像, \tilde{x} 为估计图像, $L_{\text{angle}}(\boldsymbol{\rho}^{\text{GT}}, \boldsymbol{\rho}^*)$ 为地面真实光源和估计光源之间的角误差函数, $\boldsymbol{\rho}^{\text{GT}}$ 为真实图像场景光照, $\boldsymbol{\rho}^*$ 为估计的图像场景光照, T 为阈值, α 为超参数。

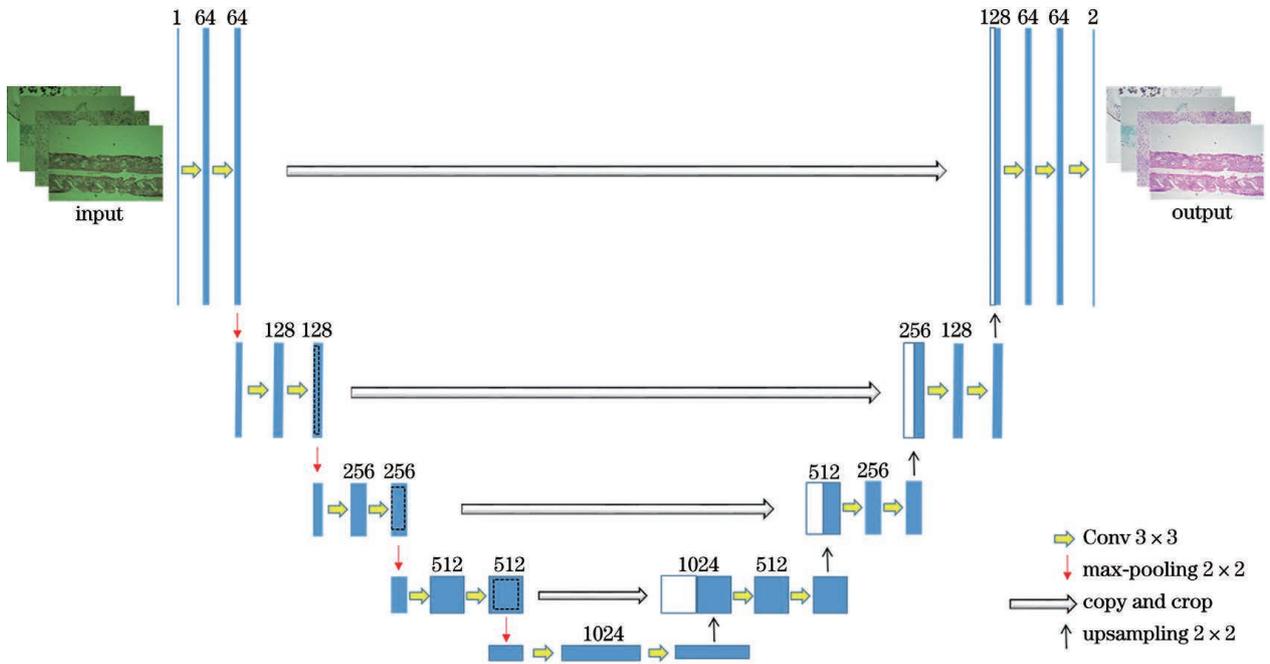


图 6 UNet 自编码的结构

Fig. 6 Structure of the UNet autoencoder

为了得到色彩恢复的最优效果,对 T 的取值进行了统计实验,包含数据集最优的前 25% 平均值 (Best25%)、总体平均值 (Mean)、中位数 (Medium)、三均值 (Trimean) 和最差的 25% 平均值 (Worst25%), 不同 T 时真实光源和估计光源之间的角误差估计值^[24]如表 1 所示。通常情况下,角误差估计值越接

近 0,表示 CC 算法恢复的图像越接近 GT 图像,其色彩还原效果就越好。可以发现,当 T 从 10 增大到 90 时,本算法的整体角误差估计值逐渐减小;当 T 从 90 增大到 180 时,整体角误差估计值呈增加趋势;当 $T=90$ 时,角误差估计值最小,色彩恢复效果最佳。因此,本算法将复合损失函数中的阈值 T 确定为 90。

表 1 阈值 T 的选取

Table 1 Selection of threshold T

| T | Best25% | Mean | Medium | Trimean | Worst25% |
|-----|-------------|-------------|-------------|-------------|-------------|
| 10 | 1.78 | 2.40 | 2.01 | 2.12 | 7.05 |
| 20 | 1.75 | 2.36 | 2.00 | 2.09 | 6.56 |
| 30 | 1.62 | 2.32 | 2.36 | 2.01 | 6.34 |
| 40 | 1.55 | 2.30 | 2.09 | 1.97 | 5.98 |
| 50 | 1.43 | 2.29 | 1.91 | 1.93 | 5.52 |
| 60 | 1.29 | 2.25 | 1.79 | 1.90 | 5.13 |
| 70 | 1.11 | 2.23 | 1.76 | 1.85 | 4.98 |
| 80 | 1.02 | 2.12 | 1.70 | 1.80 | 4.78 |
| 90 | 0.92 | 2.01 | 1.67 | 1.72 | 4.05 |
| 100 | 1.04 | 2.08 | 1.69 | 1.75 | 4.28 |
| 110 | 1.23 | 2.18 | 1.72 | 1.79 | 4.78 |
| 120 | 1.11 | 2.21 | 1.75 | 1.82 | 5.06 |
| 130 | 1.33 | 2.22 | 1.89 | 1.92 | 5.98 |
| 140 | 1.42 | 2.26 | 1.94 | 1.98 | 6.25 |
| 150 | 1.48 | 2.35 | 1.98 | 2.01 | 6.43 |
| 160 | 1.53 | 2.39 | 2.02 | 2.06 | 6.52 |
| 170 | 1.62 | 2.35 | 2.05 | 2.09 | 6.75 |
| 180 | 1.72 | 2.45 | 2.08 | 2.14 | 7.12 |

4 实验结果及分析

4.1 实验设置

为了更直观地观察本算法的实际效果,在三个 CC 数据集上进行了仿真实验,随机使用数据集的 80% 作为训练集,20% 作为测试集。实验开发的软件平台为 Python3.7 和 Matlab 2019a,电脑配置为 Intel (R) Core (TM) i9-9900K CPU,其主频为 3.60 GHz,内存为 16.00 GB, GPU 为 NVIDIA GeForce RTX 2080ti(11 GB)。

4.2 定性分析

定性分析是从主观角度评价算法还原偏色图

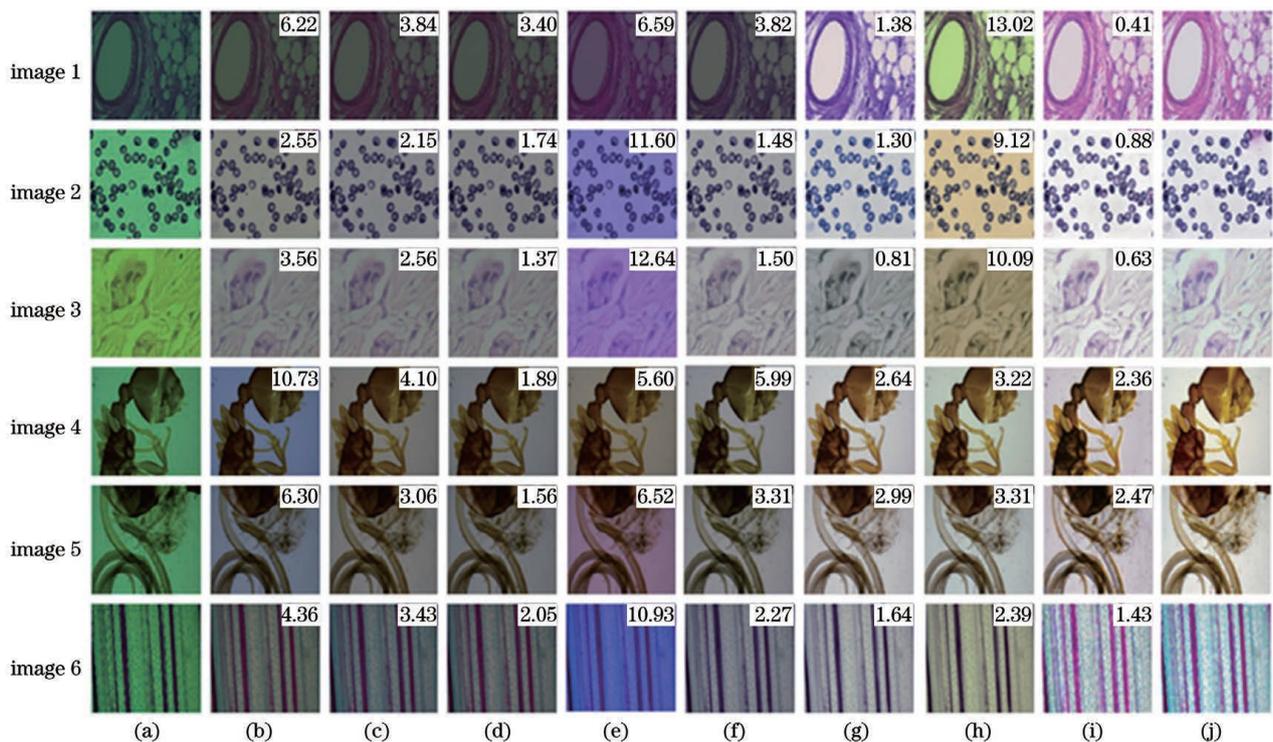


图 7 不同算法在显微 CC 数据集上的主观结果。(a)RAW;(b)文献[8];(c)文献[9];(d)文献[10];(e)文献[11];(f)文献[12];(g)文献[13];(h)文献[15];(i)本算法;(j)GT

Fig. 7 Subjective results of different algorithms in microscope color constancy dataset. (a) RAW; (b) Ref. [8]; (c) Ref. [9]; (d) Ref. [10]; (e) Ref. [11]; (f) Ref. [12]; (g) Ref. [13]; (h) Ref. [15]; (i) ours; (j) GT

4.3 定量分析

定性分析虽然直接有效,但主体的差异性可能导致不同的主观评价,为了进一步验证本算法的客观有效性及跨库训练能力,将角误差估计值作为图像的评价指标对三个不同数据集的整体训练结果进行了定量分析。其中,Best25%是算法最优能力的体现,Mean、Medium 和 Trimean 是算法综合性能的体现,Worst25%是算法整体稳定性的体现,其值均越小,表明该图像的色彩越接近于真实图像。

像的效果,可以快速直观地分辨出复原原图像的优秀。将本算法与经典的基于统计学假设的 GW、WP、SoG 和 GE 算法及比较先进的 PCA、CNN、Afifi 多偏色场景训练算法在自建显微 CC 数据集中进行了对比实验,结果如图 7 所示。其中,右上角的数值表示图像的角误差估计值。从单幅图像的角误差估计值以及主观图像观测结果可以发现,相比其他算法,本算法的色彩还原准确度更高,还原结果更接近 GT 图像。原因是复合损失函数在训练中带来的良好表现,使本算法在显微图像 CC 时具有更强的泛化性。

1) NUS-8 数据集

NUS-8 数据集的图像是由 8 款相机 (Canon1DsMkIII、Canon600D、FujifilmXM1、NikonD5200、OlympusEPL6、SonyA57、PanasonicGX1、SamsungNX2000) 在相同场景中获得的,每个相机获得的场景图像约 200 张,共包含 1736 张高质量图像,不同算法对该数据集的测试结果如表 2 所示。

2) RECommended 数据集

RECommended 数据集是经过优化升级的

表 2 不同算法在 NUS-8 CC 数据集的评估结果

Table 2 Evaluation results of different algorithms in NUS-8 CC dataset

| Algorithm | Best25% | Mean | Medium | Trimean | Worst25% |
|----------------------------------|-------------|-------------|-------------|-------------|-------------|
| GW ^[8] | 1.16 | 4.59 | 3.46 | 3.81 | 9.85 |
| WP ^[9] | 1.44 | 9.91 | 7.44 | 8.78 | 21.27 |
| Quasi-supervised ^[14] | — | 1.97 | 1.91 | — | — |
| CM ^[16] | 0.50 | 2.25 | 1.59 | 1.74 | 5.13 |
| Ref. [15] | 0.52 | 2.05 | 1.50 | — | 4.48 |
| Ref. [12] | 0.46 | 2.18 | 1.48 | 1.64 | 5.03 |
| Ref. [17] | 0.50 | 2.39 | 1.61 | 1.74 | 5.67 |
| Ref. [17](pretrained) | 0.46 | 2.35 | 1.55 | 1.73 | 5.62 |
| CNN ^[13] | 0.68 | 2.14 | 1.83 | 1.95 | 4.26 |
| UNet ^[19] | 1.13 | 2.56 | 2.04 | 2.23 | 5.17 |
| Ours | 0.92 | 2.01 | 1.67 | 1.72 | 4.05 |

Gehler-Shi 数据集^[25],其包含的图像由 2 款相机 (Canon 1D 和 Canon5D)在各种场景中获得,共包含

568 张高质量的室内室外场景图像,不同算法对该数据集的测试结果如表 3 所示。

表 3 不同算法在 RECommended CC 数据集的评估结果

Table 3 Evaluation results of different algorithms in RECommended CC dataset

| Algorithm | Best25% | Mean | Medium | Trimean | Worst25% |
|-----------------------------------|-------------|-------------|-------------|-------------|-------------|
| GW ^[8] | 5.00 | 9.70 | 10.00 | 10.00 | 13.70 |
| WP ^[9] | 2.20 | 9.10 | 6.70 | 7.80 | 18.90 |
| SoG ^[10] | 2.30 | 7.30 | 6.80 | 6.90 | 12.80 |
| GE ^[11] | 0.70 | 5.50 | 3.30 | 3.90 | 13.80 |
| CC-GANs (Pix2Pix) ^[18] | 1.20 | 3.60 | 2.80 | 3.10 | 7.20 |
| CC-GANs(CycleGAN) ^[18] | 0.70 | 3.40 | 2.60 | 2.80 | 7.30 |
| CC-GANs (StarGAN) ^[18] | 1.70 | 5.70 | 4.90 | 5.20 | 10.50 |
| CNN ^[13] | 0.80 | 2.60 | 2.00 | 2.10 | 4.00 |
| UNet ^[19] | 1.17 | 2.98 | 2.45 | 2.71 | 5.29 |
| Ours | 0.96 | 2.35 | 2.05 | 2.18 | 3.98 |

3) 自建显微数据集

在自建显微 CC 数据集上对本算法进行了测试,不同算法对该数据集的测试结果如表 4 所示。可以发现,基于深度学习的 CC 算法角误差估计结果优于统计学假设算法,原因是统计学假设算法依赖于模型中的一些假设,而假设条件并不总是满足,导致角误差估计值较大。本算法的 Worst25% 部分角误差估计值最低,这表明本算法的整体稳定性较强,Mean、

Medium 和 Trimean 部分的角误差估计值较低,表明算法的综合性能较优,在常规数码相机 CC 数据集中能够稳定恢复 RAW 数据。与同类型的 CNN 训练算法相比,未优化的 UNet 算法角误差估计值较大,但低于 CNN 算法,这表明本算法中的网络结构更有优势。训练大量数据时,改进的 UNet 结构自编码器算法角误差估计值低于其他算法,这表明本算法的色彩还原效果好,有望应用于未来数字显微相机中。

表 4 不同算法在自建显微 CC 数据集的评估结果

Table 4 Evaluation results of different algorithms in self-built microscope CC dataset

| Algorithm | Best25% | Mean | Medium | Trimean | Worst25% |
|----------------------|-------------|-------------|-------------|-------------|-------------|
| GW ^[8] | 2.26 | 5.77 | 4.81 | 5.07 | 11.94 |
| WP ^[9] | 4.43 | 6.19 | 5.04 | 5.21 | 10.60 |
| SoG ^[10] | 1.01 | 3.59 | 3.17 | 3.18 | 7.51 |
| GE ^[11] | 4.29 | 6.73 | 6.24 | 6.39 | 11.42 |
| Ref. [12] | 1.43 | 3.70 | 3.17 | 3.26 | 7.55 |
| Ref. [15] | 3.57 | 5.70 | 5.54 | 5.53 | 9.76 |
| CNN ^[13] | 0.75 | 1.98 | 1.75 | 1.81 | 4.25 |
| UNet ^[19] | 0.67 | 1.56 | 1.34 | 1.45 | 3.16 |
| Ours | 0.43 | 0.97 | 0.75 | 0.79 | 2.08 |

5 结 论

首先,结合采集的显微图像建立了一个显微 CC 数据集,并提出了一种模拟生成 RAW 图像的方法。然后,结合该数据集提出了一种半监督学习的基于自编码器 CC 算法,解决了显微镜相机 RAW 图像的偏色问题。该算法使用 UNet 从未知光照的显微相机偏色图像中学习参数值并进行训练,加入的 Inception 结构可在减少模型参数量的同时增强图像不同尺度的特征信息,并在训练过程中用复合损失函数计算误差。实验结果表明,相比其他传统算法,本算法在 NUS-8 多相机 CC 数据集和 RECommended CC 数据集及自建 CC 数据集中能够得到较低的角误差估计结果,在显微 CC 数据集的主观效果也更佳。对于神经网络训练中损失函数的参数调整,本算法通过统计实验得到,因此,后续工作还需探索更优参数的选取方法。

参 考 文 献

- [1] Li T, Zhao J F, Mao H F, et al. An efficient Fourier ptychographic microscopy imaging method based on angle illumination optimization [J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081106.
李通, 赵巨峰, 毛海锋, 等. 基于角度照明优化的傅里叶叠层显微成像方法 [J]. *激光与光电子学进展*, 2020, 57(8): 081106.
- [2] Chen Y C, Wu X, Luo Z, et al. Fourier ptychographic microscopy reconstruction based on deep learning [J]. *Laser & Optoelectronics Progress*, 2020, 57(22): 221106.
陈奕灿, 吴霞, 罗志, 等. 基于深度学习的傅里叶叠层显微成像 [J]. *激光与光电子学进展*, 2020, 57(22): 221106.
- [3] Laakom F, Passalis N, Raitoharju J, et al. Bag of color features for color constancy [J]. *IEEE Transactions on Image Processing*, 2020, 29: 7722-7734.
- [4] Laakom F, Raitoharju J, Iosifidis A, et al. Monte Carlo dropout ensembles for robust illumination estimation [EB/OL]. (2020-07-20) [2020-11-10]. <https://arxiv.org/abs/2007.10114>.
- [5] Lam W W, Oakden W, Karami E, et al. An automated segmentation pipeline for intratumoural regions in animal xenografts using machine learning and saturation transfer MRI [J]. *Scientific Reports*, 2020, 10: 8063.
- [6] Grünwald W, DeRose J. 3-dimensional imaging of macroscopic defects in aluminum alloys: image reconstruction in 3D using milling and optical microscopy [J]. *Practical Metallography*, 2020, 57(2): 96-104.
- [7] Shi Y Q, Yin Q X, Lu R S. Performance analysis of three-dimensional measurement algorithm with focus variation microscopic imaging [J]. *Laser & Optoelectronics Progress*, 2019, 56(7): 071202.
史艳琼, 尹秋霞, 卢荣胜. 变焦显微成像三维测量算法性能分析 [J]. *激光与光电子学进展*, 2019, 56(7): 071202.
- [8] Buchsbaum G. A spatial processor model for object colour perception [J]. *Journal of the Franklin Institute*, 1980, 310(1): 1-26.
- [9] Land E H, McCann J J. Lightness and retinex theory [J]. *Journal of the Optical Society of America*, 1971, 61(1): 1-11.
- [10] Elisabetta F G D T. Shades of gray and colour constancy [J]. *Color and Imaging Conference*, 2004, 2004(1): 37-41.
- [11] van de Weijer J, Gevers T, Gijzen A. Edge-based

- color constancy [J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2007, 16(9): 2207-2214.
- [12] Cheng D L, Price B, Cohen S, et al. Effective learning-based illuminant estimation using simple features [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1000-1008.
- [13] Bianco S, Cusano C, Schettini R. Color constancy using CNNs [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 81-89.
- [14] Bianco S, Cusano C. Quasi-unsupervised color constancy [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 12204-12213.
- [15] Afifi M, Brown M S. Sensor-independent illumination estimation for DNN models [EB/OL]. [2020-11-09]. <https://arxiv.org/abs/1912.06888v1>.
- [16] Gong H. Convolutional mean: a simple convolutional neural network for illuminant estimation [EB/OL]. (2020-7-20) [2020-11-10]. <https://arxiv.org/abs/2001.04911v1>.
- [17] Hernandez-Juarez D, Parisot S, Busam B, et al. A multi-hypothesis approach to color constancy [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 2267-2277.
- [18] Das P, Baslamisli A S, Liu Y, et al. Color constancy by GANs: an experimental survey [EB/OL]. (2018-12-07) [2020-11-10]. <https://arxiv.org/abs/1812.03085>
- [19] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [20] Mooney P. Kaggle breast histopathology images [EB/OL]. [2020-11-09]. <https://www.kaggle.com/paultimothymooney/breast-histopathology-images>.
- [21] Cheng D L, Prasad D K, Brown M S. Illuminant estimation for color constancy: why spatial-domain methods work and the role of the color distribution [J]. Journal of the Optical Society of America. A, Optics, Image Science, and Vision, 2014, 31(5): 1049-1058.
- [22] Hemrit G, Finlayson G D, Gijsenij A, et al. Rehabilitating the ColorChecker dataset for illuminant estimation [J]. Color and Imaging Conference, 2018, 2018(1): 350-353.
- [23] 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.
- [24] Hordley S D, Finlayson G D. Re-evaluating colour constancy algorithms [C] // Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004, August 26-26, 2004, Cambridge, UK. New York: IEEE Press, 2004: 76-79.
- [25] Gehler P V, Rother C, Blake A, et al. Bayesian color constancy revisited [C] // 2008 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA. New York: IEEE Press, 2008: 1-8.