

多通道置信度加权颜色恒常性算法

杨泽鹏, 解凯*, 李桐, 杨梦瑶, 杨斌

北京印刷学院信息工程学院, 北京 102600

摘要 颜色恒常性是实现识别、分割和三维物体重建等视觉任务的重要前提。为使计算机视觉系统具有颜色恒常性感知功能,提出多通道特征置信度加权网络,在减少网络层数和模型参数的同时充分提取图像中的特征;通过多通道置信度加权方法利用每个通道中可以为光源估计提供更多信息的特征准确估计出全局场景光源。在基于重处理的 ColorChecker 和 NUS-8 数据集上的实验结果表明,本文算法通过对特征从多通道进行置信度加权,在各项评价指标上均优于目前的颜色恒常性算法,提高了算法的精确性和稳健性,可应用于需要进行色彩校正的计算机视觉任务。

关键词 视觉光学; 颜色恒常性; 光源估计; 多通道置信度加权; 轻量级网络

中图分类号 O439

文献标志码 A

doi: 10.3788/AOS202141.1133002

Color Constancy with Multi-Channel Confidence-Weighted Method

Yang Zepeng, Xie Kai*, Li Tong, Yang Mengyao, Yang Bin

School of Information Engineering, Beijing Institute of Graphic Communication, Beijing 102600, China

Abstract Color constancy is an important prerequisite for visual tasks such as recognition, segmentation, and three-dimensional object reconstruction. We proposed a multi-channel feature-confidence-weighted network to enable the computer vision systems to perceive color constancy. As a result, the network could fully extract the features in the images while reducing the number of network layers and model parameters. The multi-channel confidence-weighted method employed the features in each channel that could provide more information for light source estimation to accurately estimate the light source in the global scene. Experimental results on the reprocessed ColorChecker and NUS-8 datasets show that the proposed algorithm, which weights the confidence of features in multiple channels, outperforms its counterparts in terms of all evaluation indexes and thus has higher accuracy and robustness. As such, this algorithm can be applied to the tasks of computer vision requiring color correction.

Key words visual optics; color constancy; illuminant estimation; multi-channel confidence-weighted; lightweight network

OCIS codes 330.4595; 300.1690; 150.0155; 150.1708

1 引言

颜色作为视觉信息中最为基础和直接的特征之一,已经被广泛应用于图像处理 and 计算机视觉领域^[1-3]。由于图像和视频成像过程中受到场景光照、物体表面的反射率以及成像传感器响应函数等多方面的影响,物体表面反射出的颜色会随着场景光源

的变化而改变。颜色恒常性算法的目的就是要消除场景中光照对物体表面颜色的影响,获取准确的物体颜色表达,为图像增强、目标分割、目标追踪、三维物体重建等计算机视觉任务提供稳定的颜色特征,这对于计算机视觉或者模式识别具有重要的理论意义和实际意义。

目前,颜色恒常性算法主要可以分为基于统计

收稿日期: 2020-12-04; 修回日期: 2021-01-04; 录用日期: 2021-01-18

基金项目: 北京市教委科研计划项目(KZ202010015021)、北京市教委科研项目(KM201810015011)

* E-mail: 2596898130@qq.com

学的方法和基于学习的方法。基于统计学的方法利用图像的低阶特征,采用某种假设条件对光照进行估计。常用的基于统计学的算法主要包括灰度世界算法(Grey-world)、灰色阴影算法(Shade-of-Grey)和灰色边缘算法(Grey-Edge)^[4]等。这类算法的优点是计算速度快,缺点是对于不同场景内容和不同光照的图像,其适应性具有局限性。

基于学习的颜色恒常性算法通过机器学习对大量已知光照颜色的图像样本进行统计和学习,利用先验知识间接地对场景光照进行估计。色域映射法^[5]是基于学习的方法中具有代表性的一种颜色恒常性算法。此外,基于学习的方法还包括概率计算的方法。这类算法的共同特点是利用统计特性得到图像场景中所有可能的光照,对于给定的图像,通常将最能代表场景图像已知的光照作为估计的光照。贝叶斯推理算法^[6]是该类算法的一个代表。相较于基于统计的方法,此类方法增强了对复杂场景的处理能力,在多数情况下提高了算法的精确性和泛化性。

深度学习在图像分类等计算机视觉任务上体现出了很好的性能,与传统方法相比,使用深度学习的方法进一步提升了颜色恒常性算法的精确性与稳定性。Bianco 等^[7]通过将图像块输入到 3 层的神经网络中预测场景光源。Qiu 等^[8]提出一种新场景光源颜色估计框架用于计算颜色恒常性,该框架将深度学习的特征提取能力与基于假设的模型的可解释性有效结合,通过特征图重载单元为图像中的图像块施加权重来对场景光源进行准确估计。Mahmoud^[9]认为用于图像分类的卷积网络结构不适用于估计场景光源,图像中的语义特征可以为估计场景光源提供更多的信息,因此他们将图像的空间特征和语义特征相结合输入到卷积神经网络中对场景光源进行估计。Afifi 等^[10]提出没有经过颜色恒常性校正的图片会对图像分割的性能产生影响,证明了颜色恒常性对于计算机视觉任务的重要性。Laakom 等^[11]将自编码网络应用于颜色恒常性,自编码网络是一种无监督学习网络,不需要使用卷积神经网络对场景光源进行估计,直接生成颜色恒常性处理后的图片。Das 等^[12]和 Sidorov^[13]将对抗生成网络应用于颜色恒常性,比较了各种对抗生成网络对于颜色恒常性的性能。Hu 等^[14]提出了一种全卷积的卷积网络结构,将数据集中的图片与置信度权重相结合对场景光源进行估计,在标准数据集上实现了更高的效率和准确性。

颜色恒常性是一个长期研究的热点问题^[15-18],目前基于深度学习的颜色恒常性算法大多是由分类或者检测网络结构改进^[19-23]而来。但由于颜色的特殊性,这些基于分类或者检测改进的网络结构应用于光源估计存在一定的局限性,主要原因有:1)颜色恒常性算法需要应用图像中存在可以为光源估计提供更多信息的局部特征估计光源,而基于分类或分割改进的网络对提取到的所有特征信息平等对待,无法充分利用可以为光源估计提供更多信息的特征来准确估计光源;2)目前基于深度学习的颜色恒常性算法忽视了图像的各个通道中均包含可以为光源估计提供更多信息的特征,网络中卷积核的跨通道信息交互过程造成了各个通道中可以为光源估计提供更多信息的特征丢失,降低了颜色恒常性算法的精确性及面对复杂环境时的稳健性;3)基于分类或者分割改进的网络结构虽然具有强大的特征提取能力,但对光源条件的改变不敏感,具有光源不变性,不能对光源颜色做出准确估计。

为了解决这些问题,本文提出多通道置信度加权网络结构,在减少网络层数和模型参数的同时通过三通道特征置信度加权的方式进一步提高了颜色恒常性算法的精确性与稳健性。本文的贡献主要包括 2 个方面:1)通过对三通道特征进行置信度加权,充分利用每个通道中可以为光源估计提供更多信息的特征,区分出有用数据和噪声数据,防止通道之间的权重相互抵消,避免了各个通道中可以为光源估计提供更多信息的特征在跨通道交互过程中丢失,使网络结构对光源信息更加敏感,提高了算法对光源估计的精确性以及面对复杂环境时的稳健性;2)对网络层数和网络模型参数进行压缩,整个网络结构为 6 层,模型参数为 0.7×10^6 ,是目前颜色恒常性算法中参数较少的网络结构,同时提高了颜色恒常性算法的运算速度。

2 多通道置信度加权算法

为了改善以往颜色恒常性算法中网络模型不能充分利用图像各个通道中可以为光源估计提供更多信息的特征估计光源、模型结构对光源信息不敏感,以及网络层数较多、网络模型参数较大的问题,本文提出多通道置信度加权颜色恒常性算法。算法的整体流程图如图 1 所示。本文算法在减少网络层数和模型参数的同时充分提取图像中的特征信息,通过多通道置信度加权的方式利用各个通道中可以为光源估计提供更多信息的特征估计光源,增强了网络

结构对光源变化的敏感性,进一步提高了颜色恒常性算法的精确性与面对复杂环境时的稳健性。算法的整体流程如下:1)对数据集进行预处理;2)将预处理后的图片输入到多通道置信度加权网络结构中充分提取图像的特征信息;3)从三个通道对提取到的特

征进行置信度加权,对特征进行区分,提取出可以为光源估计提供更多信息的特征;4)通过置信度池化的方式利用可以为光源估计提供更多信息的特征准确估计出光源。5)对图像进行校正,将估计出的场景光源从原始图像中移除,得到标准光源下的图像。




图 1 网络结构图

Fig. 1 Network structure

2.1 颜色恒常性算法分析

对于给定的彩色 RGB 图像,颜色恒常性任务的目标是尽可能准确地估计出场景光源,并使用对角偏移模型将估计出的场景光源进行移除,使图像恢复到标准光源(通常为白色)下的颜色。如图 2 所示。




图 2 基于颜色恒常性算法流程图

Fig. 2 Flow chart of the color constancy algorithm

用公式可以表示为

$$f(I_n) = c_g = \sum_{i \in R} \sum_{j=1}^3 s(R_{ij})c(R_{ij}), \quad (1)$$

式中: I_n 表示输入的图像; c_g 表示估计出的场景光源。颜色恒常性算法的目的是找出 $f(I_n)$, 使 c_g 无限接近于真实的场景光源。本文算法中, $f(I_n)$ 是

多通道特征置信度加权网络,在充分提取图像中的特征信息后从多个通道为特征信息进行置信度加权,根据每个通道的特征可以为光源估计提供的价值给予不同的置信度权重,最后使用置信度池化估计出场景光源。公式中 $c(R_{ij})$ 表示图像中的像素点, $s(R_{ij})$ 表示置信度加权函数, j 表示通道数目, $s(R_{ij})c(R_{ij})$ 表示根据图像中的信息特征为光源估计提供的信息价值进行置信度加权。实验结果表明,本文算法压缩了网络层数和模型参数,通过对三通道特征值置信度加权,充分利用图像每个通道中可以为光源估计提供更多信息的特征估计光源,提高了算法的精确性和稳健性。

2.2 多通道置信度加权

由于光源颜色的特殊性和敏感性,若图像中的物体包含有任意的反射率,则可以存在多种光照解释图像中物体所展现出来的颜色,导致光源估计存在不确定性的问题,如图 3 所示。同时,图像中部分区域(例如含有固定颜色的物体、较多纹理特征、高亮区域)可以为光源估计提供更多的特征信息。因此,应用于颜色恒常性算法的网络结构应该充分利

用可以为光源估计提供更多信息的特征估计光源, 并抑制导致光源估计不确定问题的区域特征, 并对

光源变化具有较强的敏感性。

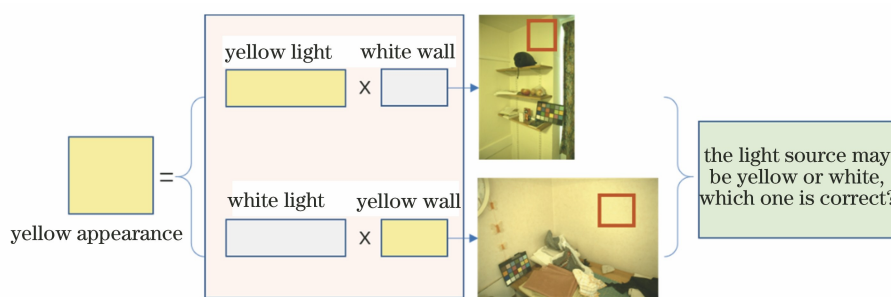


图 3 光源估计不确定

Fig. 3 Ambiguous of the light source estimation

置信度加权方法能够筛选出可以为光源估计提供更多信息的特征, 但图像各个通道中均包含可以为光源估计提供更多信息的特征, 若直接对图像中的区域进行置信度加权则各相邻通道之间置信度权重会平均抵消。当图像中某一区域的其中一个通道可以为光源估计提供更多的特征信息时, 会对通道特征赋予较高的置信度权重。若相邻通道的特征不能为光源估计提供信息或者造成了光源不确定的问题而赋予了较低权重, 则在该区域进行置信度加权时两个通道的置信度权重会进行平均, 使其高置信度权重降低, 导致网络结构在估计光源时无法充

分利用该区域可以为光源估计提供更多信息的特征准确估计出光源。如图 4 所示, 由于对图像区域进行整体置信度加权时存在置信度权重相互平均抵消, 与多通道特征置信度加权相比, 对区域整体进行置信度加权时, 高置信度权重区域个数减少了 36.84%, 导致网络不能充分利用图像各个通道中可以为光源估计提供更多信息的特征估计光源。因此, 本文提出多通道置信度加权的方式, 充分利用图像各个通道中可以为光源估计提供更多信息的特征, 增强了网络模型对光源变化的敏感度, 提高了算法的精确性与面对复杂环境时的稳定性。

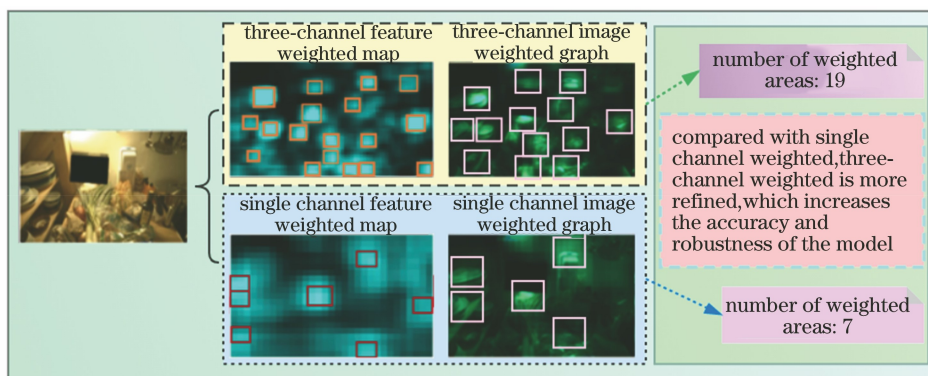


图 4 单通道与三通道光源特征置信度加权区域数量对比图

Fig. 4 Comparison of the number of confidence-weighted areas of single-channel and three-channel light source

2.3 多通道置信度加权网络结构

光源估计不同于以往的图像分类或者目标检测任务, 传统的网络结构加深网络层数可以更加充分地提取图像中的全局特征信息从而提高准确率, 由于光照变化不会影响物体的检测和分割, 基于分类和检测改进的结构具有光源不变性, 不适用于光源估计, 网络层数的加深并不会提高光源估计的准确性。同时, 目前用于颜色恒常性估计的数据集规模较小, 不适用于大规模网络的训练, 网络层数过深也会导致算法在时间和能源消耗方面效率低下。因

此, 无法直接使用传统的深层卷积网络结构提取特征用于颜色恒常性算法中的光源估计。

多通道置信度加权网络结构由 6 个卷积层组成, 网络结构如图 1 所示。算法通过前四个卷积层充分提取图像中的特征信息, 之后的两个卷积层对提取到的特征从三个通道进行置信度加权并输出最终估计的场景光源。为了减少网络中的模型参数, 网络结构中的第 2~4 卷积层使用 1×1 和 3×3 大小卷积核的 CC 模块替代, CC 模块的网络结构图如图 5 所示, 每个 CC 模块包含三个卷积层, 将其分别

命名为 CC_1、CC_2、CC_3。多通道置信度加权网络卷积层 1 接收彩色图像的输入,由 64 个大小为 3×3 的卷积核构成。卷积层 1 后连接卷积核大小为 3,步长为 2 的最大池化层。之后连接 2 个 CC 模块,2 个 CC 模块中 CC_1 卷积核的个数为 16,CC_2 和 CC_3 的卷积核的大小为 64,对输出使用卷积核大小为 3,步长为 2 的最大池化。池化层后连接 1 个 CC 模块,该 CC 模块中 CC_1 卷积核的个数为 32,CC_2 和 CC_3 卷积核的个数为 128,对输出使用卷积核大小为 3,步长为 2 的最大池化。之后连接两个卷积层对提取到的特征进行置信度池化加权,第一个卷积层由 64 个大小为 6×6 的卷积核组成,第二个卷积层是由 6 个大小为 1×1 的卷积核组成,最后输出估计的场景光源。网络结构在减少网络层数和模型参数的同时充分提取图像中的特征信息,通过多通道置信度加权充分利用图像各个通道中可以为光源估计提供更多信息的特征估计光源,提高了颜色恒常性算法的精确性和面对复杂环境时的稳健性。网络模型参数为 0.7×10^6 ,是目前颜色恒常性算法中参数较少的网络结构,提高了颜色恒常性算法的运算速度。

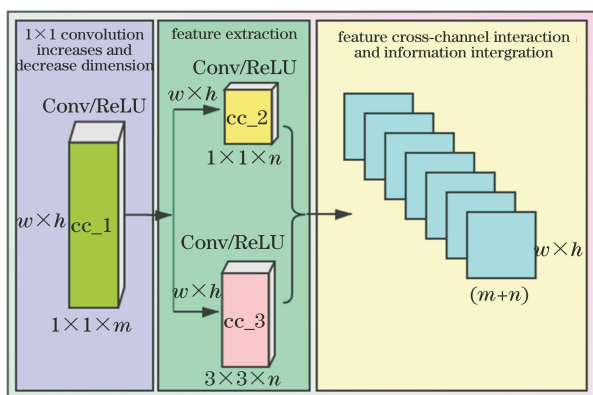


图 5 CC 模块网络结构图

Fig. 5 CC module network structure diagram

为了测试本文算法使用 6 层网络结构的有效性,在实验过程中对网络层数进行加深,当网络层数为 7、8 层时算法的精确性和稳健性并没有随着网络层数的加深而提高,这是因为 6 层的网络结构已经可以充分提取图像中的特征信息,并通过三通道置信度加权方法充分利用每个通道中可以为光源估计提供更多信息的特征准确估计出光源,而由于加深网络层数提取到更多的特征不会为光源估计提供更多的信息,在进行置信度加权时这些特征会被去除。当网络层数达到 9 层时,算法的精确性开始逐步下降,这是因为层数过深造成了过拟合。将网络层数

减少到 5 层,算法的精确度开始下降,这是因为网络结构提取的特征信息不足导致无法对场景光源进行准确估计。

本文算法以及其他基于深度学习的颜色恒常性算法的网络参数数量如表 1 所示,将其用于衡量各种算法理论上的训练时间复杂度和空间复杂度,并与本文方法对比。Lou 等^[22]使用的卷积神经网络参数数量为 5.69×10^7 ,是本文算法的 81.3 倍,Bianco 等^[7]使用的卷积神经网络参数为 1.49×10^7 ,是本文算法使用参数的 21 倍,Shi 等^[23]提出的网络结构参数数量为 4.2×10^6 ,是本文算法的 6 倍。FC4(AlexNet)^[14]网络结构使用的参数数量为本文算法的 4 倍,FC4(SqueezeNet)^[14]网络结构使用的参数数量为本文算法的 2 倍,IEN+PSN^[21]网络结构使用的参数数量为本文算法的 2 倍。表 1 数据表明,本文方法在目前所有的基于深度学习的颜色恒常性算法中采用 6 层的网络结构,使用了较少的模型参数,为 0.7×10^6 ,是轻量级的网络。

表 1 本文算法与其他算法网络参数数量对比

Table 1 Comparison of the number of network parameters between proposed algorithm and other algorithms

Method	Number of parameters /M
Lou ^[22]	56.9
CNN ^[7]	14.9
DS-Net ^[23]	4.2
FC4(AlexNet) ^[14]	2.9
FC4(SqueezeNet) ^[14]	1.2
IEN+PSN ^[21]	1.6
Proposed method	0.7

3 实验与结果分析

为验证本文算法的有效性,实验在两组单光源数据集上进行,并将本文方法与其他颜色恒常性算法的误差进行对比,分析本文算法的有效性。

实验环境为 3.00 GHz 的英特尔 i7CPU,16 GB 内存,GPU 为 Nvidia GeForce GTX 2080,12 GB 显存,操作系统为 64 位 Ubuntu 20.02,本文提出的多通道特征置信度加权全卷积神经网络结构基于 tensorflow 1.14.0 平台实现。

3.1 数据集

1) 重处理的 ColorChecker 数据集^[24]。本文选用重处理的 ColorChecker 数据集为 Shi 等在原始 ColorChecker 数据集 RAW 图像的基础上进行线性化处理得到。该数据集中包含由 Canon1D 和 Canon5D 拍摄的 568 幅图像以及每幅图像所对应

的真实场景光源和颜色检查器的坐标信息。颜色检查器可以为图片提供真实的场景光源信息。在使用数据集对本文算法进行训练之前,根据每张图片中颜色检查器的坐标信息对颜色检查器进行遮挡防止对网络训练造成干扰。将数据集中的 568 张图片分为三部分用于三重交叉验证。第一部分包括 189 张图片,经过数据增强后用于网络训练,第二部分包括 191 张图片用于网络模型测试,第三部分包括 188 张图片用于验证。

2) NUS-8 数据集^[25]。该数据集中包括用 8 种相机拍摄的 1736 张图片,数据集中的每张图像包含用于提供光源颜色真实值的颜色检查器,使用时该部分图像被遮住。每个子集约 200 幅图像,分辨率



图 6 数据集示例图

Fig. 6 Samples of the dataset

3.3 网络训练

使用二阶段训练法对本文方法进行训练。第一阶段使用 ImageNet 数据集对多通道置信度加权网络进行训练,对网络模型中的参数进行初始化。第

基本均为 2000 以上。NUS-8 数据集包括了多种相机在更加丰富的真实场景光源下拍摄的图像,可以更加准确地测试颜色恒常性算法的稳定性。

3.2 数据集预处理

由于用于训练网络的数据集规模较小,在网络训练之前需要对数据集进行数据增强及预处理。方法为随机选择原始图像较短边的 0.1~1,然后选择正方形区域对图像进行裁剪,将选择到的图像随机旋转,并以 0.6 的概率对图像进行左右翻转,以 0.5 的概率对图像进行上下翻转,对数据集中的图像进行打乱后选择一个批次的图像输入到网络中进行训练。将伽马校正应用于线性 RGB 图像对图像进行显示,经过预处理后的图像如图 6 所示。

二阶段使用重处理的 ColorChecker 数据集集中的训练集,经过数据增强后对网络进行迭代训练,最终使网络准确估计出场景光源。二阶段训练法流程图如图 7 所示。

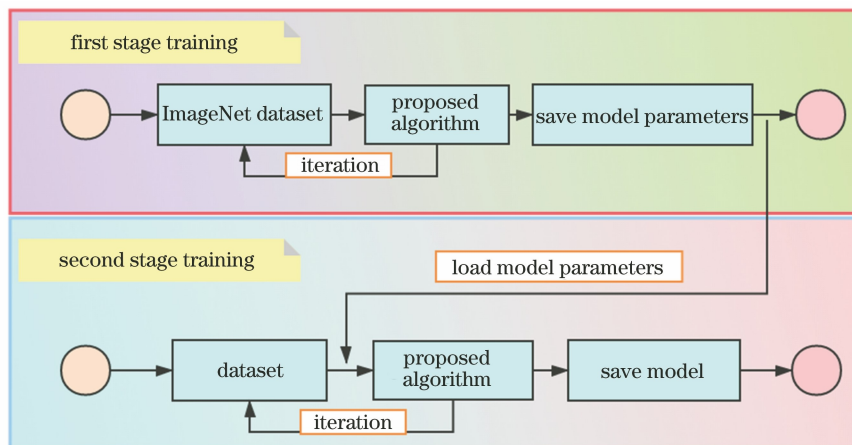


图 7 网络训练步骤图

Fig. 7 Diagram of the network training stage

对网络结构中的超参数调整进行比较,选取可以实现最高准确率和效率的超参数。网络训练中的批大小(batch-size)设置为 64,学习率设置为 1×10^{-4} 。在网络训练过程中,随着迭代次数的不断增加,学习率将逐渐按照比例进行衰减。对于网络结构中的第

二个卷积层,采用 0.5 的丢弃率防止网络过拟合。将网络训练的迭代次数设置为 12000 次,在网络训练过程中采用截断训练法,在训练过程中如果损失函数值已经基本趋向于稳定,则网络自动停止训练。实验表明,当网络训练至 10000 次时,网络损失函数值已经

基本趋向于稳定,网络接近于收敛停止训练。对训练过程进行可视化,网络训练过程中损失值如图 8 所

示,其中横坐标表示训练过程中的迭代次数,纵坐标表示根据角度误差计算出的损失值。




图 8 网络训练损失值曲线图

Fig. 8 Graph of the network training loss value

3.4 评价指标

本文采用角度误差作为光源颜色估计误差度量方式。网络模型的性能通过比较真实场景光源与本文算法估计得到的光源获得。角度误差的数学公式为

$$d_e(\mathbf{e}_g, \mathbf{e}_u) = \arccos\left(\frac{\mathbf{e}_g \cdot \mathbf{e}_u}{\|\mathbf{e}_g\| \cdot \|\mathbf{e}_u\|}\right), \quad (2)$$

式中: $\mathbf{e}_g = [e_g^R, e_g^G, e_g^B]$ 表示数据集中的真实场景光源标签; $\mathbf{e}_u = [e_u^R, e_u^G, e_u^B]$ 表示使用本文算法估计出的场景光源; $\mathbf{e}_g \cdot \mathbf{e}_u$ 表示真实场景光源与估计光源之间的内积操作; $\|\cdot\|$ 表示向量的欧几里得范数。角度误差值代表本文算法估计出的场景光源与真实光源之间的接近程度。本文主要对比光源颜色估计角度误差的均值、中位数、三均值、最优 25% 均值、最差 25% 均值和 95th 百分位数。其中角度误差均值用于估计算法的总体性能,中位数和三均值用于测试离散值对算法的影响,最差 25% 均值和 95th 百分位数衡量算法在面对复杂环境时的角度误差,其值越小说明算法的鲁棒性和稳健性越好。

3.5 与其他算法对比分析

在 NUS-8 数据集上分别对每个相机的图像子集采用三重交叉验证,得到各个子集光源颜色估计误差的中值、均值、三均值、最好 25% 均值、最差 25% 均值的统计结果,将所有子集误差统计结果的几何平均值作为最终的误差结果,并将本文算法与目前存在的基于统计的颜色恒常性算法和基于学习的颜色恒常性算法做出比较,实验结果如表 2 所示。其中 Grey-world^[26] 算法假设图像中 R、G、B 三个通道的平均值应等于一个固定的值, White-Patch^[27] 算法假设图像中像素值最大点处的色彩信息为当前光源的信息。Shades-of-Grey^[28] 算法是对 Grey-world^[26] 算法的改进, 1-order Grey Edge^[4] 和 2-order Grey Edge^[4] 利用图像的空间导数特征信息

对图像进行色彩校正, Pixel-based Gamut^[29] 和 Edge-based Gamut^[29] 算法表明应用图像的高阶导数特征会有更好的光照估计效果。Bayesian^[6] 算法是基于机器学习的颜色恒常性算法,通过手工提取特征对光照进行光源估计。Using CNNs^[7] 算法使用五层网络结构对光照进行估计。Deep Color constancy^[22] 算法使用深层卷积网络对光源进行准确估计。CCC^[30] 算法使用卷积神经网络对光源进行估计。CC-GANs^[13] 算法利用对抗神经网络对光源进行准确估计。FC4^[14] 算法通过全卷积网络对光源进行准确估计。IEN+PSN^[21] 算法通过挑选图像块和光源估计两个网络分支结构估计出最后的场景光源。Multi-Hypothesis^[31] 算法估计出多种光源并对其进行线性组合增强了算法的鲁棒性。

NUS-8 数据集的场景光源丰富,更加考验模型在面对复杂环境时模型的稳健性。实验结果表明,本文方法在该数据集上的 5 个评价指标上均超过了目前的颜色恒常性算法。在中值误差、均值误差、三均值误差、最好 25% 均值和最差 25% 均值 5 个评价指标上,本文算法比目前效果最好的颜色恒常性算法分别提升了 25%、23%、9%、21%、27%。网络结构在减少网络层数和网络参数数量的同时有效提取图像中的特征,通过三通道特征置信度加权方式充分利用不同通道中可以为光源估计提供更多信息的特征,提高了算法的精确性和面对复杂环境时的稳健性,是目前颜色恒常性算法中精确度最高的算法,同时也是稳健性和泛化性最好的算法。

在重新处理的 ColorChecker 数据集上,采用数据集提供的三重交叉验证计算误差。分别对角度误差的均值、中值、三均值、最好 25% 均值、最差 25% 均值和 95th 百分位数进行统计,并与其他颜色恒常性算法进行对比。如表 3 所示。

表 2 使用 NUS-8 camera 数据集测试误差结果

Table 2 Test error results using NUS-8 camera data set

Method	Mean	Median	Triple mean	Best 25%	Worst 25%
Grey-word ^[26]	4.140	3.200	3.390	0.900	9.000
White-Patch ^[27]	10.620	10.580	10.490	1.860	19.450
Shades-of-Grey ^[28]	3.400	2.570	2.730	0.770	7.410
1-order Grey Edge ^[4]	3.200	2.220	2.430	0.720	7.360
2-order Grey Edge ^[4]	3.200	2.260	2.440	0.750	7.270
Pixel-based Gamut ^[29]	7.700	6.710	6.900	2.510	14.050
Edge-based Gamut ^[29]	8.430	7.050	7.370	2.410	16.080
Bayesian ^[6]	3.670	2.730	2.910	0.820	8.210
Using CNNs ^[7]	7.600	6.900	7.400	3.000	12.400
Deep color constancy ^[22]	6.200	5.000	5.400	3.900	8.600
CCC ^[30]	2.800	1.800	1.900	0.850	6.300
CC-GANs(pix-pix) ^[13]	3.800	3.000	3.700	1.900	8.400
FC4-AlexNet ^[14]	2.120	1.530	1.670	0.480	4.780
FC4-SqueezeNet ^[14]	2.230	1.570	1.270	0.470	5.150
IEN+PSN ^[21]	2.100	1.350	1.510	0.450	5.010
Multi-Hypothesis ^[31]	2.350	1.550	1.730	0.460	5.620
Proposed method	1.566	1.032	1.162	0.352	3.472

表 3 使用重处理的 ColorChecker 数据集测试误差结果

Table 3 Test error results using the reprocessed ColorChecker data set

Method	Mean	Median	Triple mean	Best 25%	Worst 25%	95th
Grey-world ^[26]	10.700	10.600	10.700	3.450	12.300	17.400
White-Patch ^[27]	9.800	8.000	8.900	3.800	13.600	22.300
Shades-of-Grey ^[28]	8.300	7.500	7.800	2.900	11.800	17.000
1-order Grey Edge ^[4]	5.000	3.700	4.100	3.900	10.100	13.300
2-order Grey Edge ^[4]	5.400	4.500	4.800	2.600	9.800	12.800
Pixel-based Gamut ^[29]	6.900	5.200	5.700	1.800	11.700	18.200
Edge-based Gamut ^[29]	6.900	4.600	5.200	2.100	14.600	20.600
Bayesian ^[6]	6.600	4.600	5.200	3.200	10.900	18.400
General Grey-World ^[32]	7.600	6.700	7.000	3.800	12.100	16.500
Using CNNs ^[7]	8.200	6.300	6.800	2.600	11.300	20.400
Deep color constancy ^[22]	5.700	4.700	5.000	3.200	8.400	12.400
Exemplar-Based ^[33]	2.890	2.270	2.420	0.820	5.970	6.950
CCC(dist+ext) ^[30]	2.000	1.220	1.400	0.350	4.760	5.850
CC-GANs(Pix2Pix) ^[13]	3.600	2.800	3.100	1.200	7.200	9.400
FC4-AlexNet ^[14]	1.770	1.110	1.290	0.340	4.290	5.440
FC4-SqueezeNet ^[14]	1.650	1.180	1.270	0.380	3.780	4.730
IEN+PSN ^[21]	2.250	1.590	1.730	0.590	5.030	6.080
Multi-Hypothesis ^[31]	2.100	1.320	1.530	0.360	5.100	—
Proposed method	1.574	1.030	1.119	0.300	3.475	4.039

表 3 的实验结果表明,本文方法在所有算法中准确性最高,稳健性最好。与传统的颜色恒常性算法相比,基于深度学习的颜色恒常性算法在 6 个评价指标上均优于传统的颜色恒常性算法。在基于深度学习的颜色恒常性算法中,本文方法在 6 个评价指标上均超过了目前的颜色恒常性算法,证明了本

文算法的有效性。本文方法在 NUS-8 数据集和重处理的 ColorChecker 数据集上对每幅图像进行颜色恒常性处理的平均时间为 0.017 s,可以满足实际问题需要。

本文算法的输出结果如图 9 所示,图 9(a)表示输入图像,图 9(b)表示使用本文算法估计颜色

光源校正后的图像,图 9(c)表示本文算法对图像中的特征从三个通道进行置信度加权的权重分配图。图像中亮度较大的区域表示可以为光源估计提供更多信息的特征,给予更高的权重值,图 9(d)表示标准光源下的图像,图 9(e)表示 Grey-world 算法校正后的图像,图 9(f)表示 White-Patch 算法校正后的图像,图 9(g)表示 Shades-of-Grey 算法校正后的图像,图 9(h)表示 Grey-Edge 算法校正后的图像。将本文方法和其他四种方法与标准光源下

的图片进行比较,从主观视觉上可以看出, Grey-world 算法、White-Patch 算法、Shades-of-Grey 算法、Grey-Edge 算法均存在局限性,本文算法通过从三个通道对特征值进行加权,区分出每个通道中可以为光源估计提供更多信息的特征,避免了各个通道的置信度权重值平均相互抵消,充分利用各个通道中可以为光源估计提供更多信息的特征估计光源,提高了算法对光源估计的准确性与稳健性。

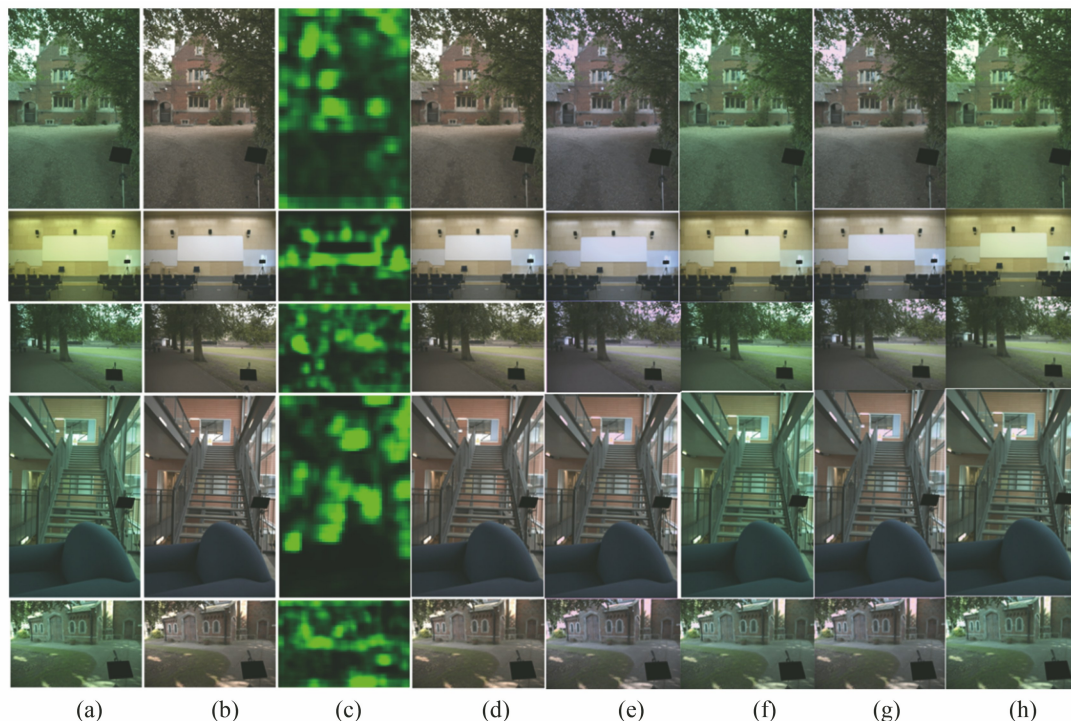


图 9 网络测试可视化。(a)输入图像;(b)本文算法估计光源校正后的图像;(c)本文算法对图像多通道置信度加权的权重分配图;(d)标准光源;(e) Grey-world 算法;(f) White-Patch 算法;(g) Shades-of-Grey 算法;(h) Grey-Edge 算法

Fig. 9 Visualization of the network output. (a) Input images; (b) using proposed algorithm to estimate images corrected by light source; (c) weight distribution diagrams of proposed algorithm to weight the image multi-channel confidence; (d) standard light source; (e) Grey-world algorithm; (f) White-Patch algorithm; (g) Shades-of-Grey algorithm; (h) Grey-Edge algorithm

4 结 论

为了充分利用图像各个通道中可以为光源估计提供更多信息的特征估计光源,缩减网络层数和网络模型参数,提升算法在时间和能源消耗方面的效率,本文提出多通道置信度加权颜色恒常性算法,与现有的颜色恒常性算法相比,本文算法通过对三个通道的特征进行置信度加权,充分利用各个通道中可以为光源估计提供更多信息的特征估计光源,增强了算法对光源变化的敏感度,提高了颜色恒常性算法的精确性以及算法在面对复杂环境时的稳健性

和泛化性。同时,本文算法对网络层数和模型参数进行压缩,算法包括 6 层网络,模型参数为 0.7×10^6 ,是轻量级的网络,提高了颜色恒常性算法的运算速度。实验结果表明,本文算法在各项评价指标上均优于目前的颜色恒常性算法。在 NUS-8 数据集均值和中值评价指标上,本文算法比目前效果最好的颜色恒常性算法提升了 25% 和 23%,在 Worst 25% 评价指标上提升了 27%,在重处理的 ColorChecker 数据集上,本文算法在各个评价指标上均得到了提升,证明了本文算法的有效性。随着深度学习的发展,在其他领域出现了一些新的网络

模型并取得了较好的结果,如生成式对抗网络,下一步的工作将针对该方向以及多光源条件下的图像颜色校正进行深入研究。

参 考 文 献

- [1] Wu L X, Xu M, Zhu G B, et al. Appearance features in encoding color space for visual surveillance [J]. *Neurocomputing*, 2018, 308: 21-30.
- [2] Lu Z, Jiang X D, Kot A, et al. Color space construction by optimizing luminance and chrominance components for face recognition [J]. *Pattern Recognition*, 2018, 83: 456-468.
- [3] Rabie T. Training-less color object recognition for autonomous robotics [J]. *Information Sciences*, 2017, 418/419: 218-241.
- [4] van de Weijer J, Gevers T, Gijzen A, et al. Edge-based color constancy [J]. *IEEE Transactions on Image Processing*, 2007, 16(9): 2207-2214.
- [5] Finlayson G, Hordley S. Selection for gamut mapping colour constancy [J]. *Image and Vision Computing*, 1999, 17(8): 597-604.
- [6] Brainard D H, Freeman W T. Bayesian color constancy [J]. *Journal of the Optical Society of America: A, Optics, Image Science, and Vision*, 1997, 14(7): 1393-1411.
- [7] Bianco S, Cusano C, Schettini R, et al. 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.
- [8] Qiu J Q, Xu H S, Ye Z N, et al. Color constancy by reweighting image feature maps [J]. *IEEE Transactions on Image Processing*, 2020, 29: 5711-5721.
- [9] Mahmoud A. Semantic white balance: semantic color constancy using convolutional neural network [EB/OL]. (2018-5-31)[2020-11-13]. <https://arxiv.org/abs/1802.00153>.
- [10] Afifi M, Brown M. What else can fool deep learning? Addressing color constancy errors on deep neural network performance[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 243-252.
- [11] Laakom F, Raitoharju J, Iosifidis A, et al. Color constancy convolutional autoencoder[C]//2019 IEEE Symposium Series on Computational Intelligence (SSCI), December 6-9, 2019, Xiamen, China. New York: IEEE Press, 2019: 1085-1090.
- [12] Das P, Baslamisli A S, Liu Y, et al. Color constancy by GANs: an experimental survey[EB/OL]. (2018-12-07)[2020-11-20]. <https://arxiv.org/abs/1812.03085>.
- [13] Sidorov O. Conditional GANs for multi-illuminant color constancy: revolution or yet another approach? [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 16-17, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 1748-1758.
- [14] Hu Y M, Wang B Y, Lin S, et al. FC⁴: fully convolutional color constancy with confidence-weighted pooling [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 330-339.
- [15] Ma R Q, Liao N F. Influence of illuminant chromaticity on color constancy under RGB-LED light source [J]. *Acta Optica Sinica*, 2019, 39(9): 0933001.
马瑞青, 廖宁放. RGB-LED 光源下光源色度对颜色恒常性的影响 [J]. *光学学报*, 2019, 39(9): 0933001.
- [16] Wang G L, Tian J D, Li P Y, et al. Image color correction based on double transmission underwater imaging model[J]. *Acta Optica Sinica*, 2019, 39(9): 0901002.
王国霖, 田建东, 李鹏越, 等. 基于双透射率水下成像模型的图像颜色校正 [J]. *光学学报*, 2019, 39(9): 0901002.
- [17] Li X Y, Yang H J, Yan Z, et al. Image background blurring algorithm based on color constancy [J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081001.
李晓颖, 杨恒杰, 闫铮, 等. 基于颜色恒常性的图像背景虚化算法 [J]. *激光与光电子学进展*, 2020, 57(8): 081001.
- [18] Zhang W, Guo J C. Low-illumination underwater image enhancement based on white balance and relative total variation[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121016.
张薇, 郭继昌. 基于白平衡和相对全变分的低照度水下图像增强 [J]. *激光与光电子学进展*, 2020, 57(12): 121016.
- [19] Sidorov O. Artificial color constancy via GoogLeNet with angular loss function [J]. *Applied Artificial Intelligence*, 2020, 34(9): 643-655.
- [20] Košević K, Subašić M, Lončarić S, et al. Attention-based convolutional neural network for computer vision color constancy [C] // 2019 11th International Symposium on Image and Signal Processing and

- Analysis (ISPA), September 23-25, 2019, Dubrovnik, Croatia. New York: IEEE Press, 2019: 372-377.
- [21] Cui S, Zhang J, Gao J, et al. Illuminant estimation via deep residual learning[J]. *Journal of Image and Graphics*, 2019, 24(12): 2111-2125.
崔帅, 张骏, 高隽, 等. 深度残差学习下的光源颜色估计[J]. *中国图象图形学报*, 2019, 24(12): 2111-2125.
- [22] Lou Z Y, Gevers T, Hu N H, et al. Color constancy by deep learning [C] // *Proceedings of the British Machine Vision Conference 2015*, September 7-10, 2015, Swansea, UK. Durham: BMVA Press, 2015: 76.1-76.12.
- [23] Shi W, Loy C C, Tang X O, et al. Deep specialized network for illuminant estimation [M] // Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016*. Lecture notes in computer science. Cham: Springer, 2016, 9908, 371-387.
- [24] Shi L, Funt B. Re-processed vision of the gehler color constancy dataset of 568 images [EB/OL]. (2014-9) [2020-11-15]. <http://www.cs.sfu.ca/~color/data/.6>.
- [25] Cheng D L, Prasad D K, Brown M S, et al. 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*, 2014, 31(5): 1049-1058.
- [26] Buchsbaum G. A spatial processor model for object colour perception [J]. *Journal of the Franklin Institute*, 1980, 310(1): 1-26.
- [27] Brainard D H, Wandell B A. Analysis of the retinex theory of color vision [J]. *Journal of the Optical Society of America: A, Optics and Image Science*, 1986, 3(10): 1651-1661.
- [28] Finlayson G D, Trezzi E. Shades of gray and color constancy[C] // *Color and Imaging Conference, 12th Color and Imaging Conference Final Program and Proceedings*, November 9, 2004, Scottsdale, Arizona, USA. New York: Society for Imaging Science and Technology, 2004: 47-52.
- [29] Barnard K. Improvements to gamut mapping colour constancy algorithms [M] // *Computer vision-ECCV 2000*. Lecture notes in computer science. Heidelberg: Springer, 2000, 1842: 390-403.
- [30] Barron J T. Convolutional color constancy[C] // *2015 IEEE International Conference on Computer Vision (ICCV)*, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 379-387.
- [31] Juarez D H, 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.
- [32] Barnard K, Martin L, Coath A, et al. A comparison of computational color constancy algorithms. II. experiments with image data[J]. *IEEE Transactions on Image Processing*, 2002, 11(9): 985-996.
- [33] Joze H R V, Drew M S. Exemplar-based color constancy and multiple illumination [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(5): 860-873.