

图文信息技术

基于颜色空间变换和 CNN 的自适应去模糊方法

王晓红¹, 卢辉¹, 黄中秋¹, 麻祥才²

(1.上海理工大学, 上海 200093; 2.上海出版印刷高等专科学校, 上海 200093)

摘要: **目的** 研究数字图像中的去模糊问题, 从受损的模糊图像中恢复出清晰图像。**方法** 针对现有图像去模糊算法无法保留图像高频信息及容易产生振铃效应等问题, 提出一种基于 Y 通道反卷积和卷积神经网络的两阶段自适应去模糊算法 (SDYCNN)。在第 1 阶段, 将数字图像转换至 YUV 颜色空间, 根据图像无参考质量评价分数与模糊核尺寸之间的对应关系, 在 Y 通道内自适应确定模糊核尺寸并进行反卷积增强; 第 2 阶段将第 1 阶段中的反卷积增强作为预处理方式, 通过 4 层卷积神经网络建立反卷积增强后的图像与清晰图像之间的映射关系, 实现图像去模糊。**结果** 轻微模糊图像在第 1 阶段便能够得到较好的去模糊效果, 严重模糊图像经过第 1 阶段的反卷积增强, 也有助于神经网络中特征的快速提取。**结论** 实验结果表明, 该算法不仅对于模糊图像具有良好的恢复效果, 运算效率也有显著提升。

关键词: YUV 颜色空间; 去模糊; 卷积神经网络; 反卷积; 无参考图像质量评价

中图分类号: TS206 **文献标识码:** A **文章编号:** 1001-3563(2020)07-0224-10

DOI: 10.19554/j.cnki.1001-3563.2020.07.032

Self-adaptive Deblurring Algorithm Based on Color Space Conversion and CNN

WANG Xiao-hong¹, LU Hui¹, HUANG Zhong-qiu¹, MA Xiang-cai²

(1.University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Shanghai Publishing and Printing College, Shanghai 200093, China)

ABSTRACT: The work aims to research the deblurring methods in digital image processing that restore clear images from damaged blurred ones. A two-stage self-adaptive deblurring algorithm based on deconvolution and convolutional neural network in Y channel (SDYCNN) was proposed, with respect to the problem that the existing deblurring algorithm could not preserve the high frequency information of the images and was likely to result in ringing effect. In the first stage, the digital images were transferred to YUV color space. According to the correspondence relationship between the image with no reference quality assessment scores and the blur kernel size, the blur kernel size was adaptively determined and the deconvolution enhancement was done in Y channel. In the second stage, the deconvolution enhancement in the first stage was taken as the preprocessing method. The mapping relationship between the deconvolution-enhanced images and ground truth images was established by 4-layer convolutional neural network and could be used for image deblurring. The first stage was sufficient to achieve satisfactory results for slightly blurred image. The severely blurred images after the deconvolution enhancement in the first stage were also helpful for the rapid feature extraction in neural network. Experiment results demonstrate that the proposed algorithm can not only properly restore the blurred images, but also significantly improve the compute efficiency.

KEY WORDS: YUV color space; deblurring; convolutional neural network; deconvolution; no reference image quality assessment

收稿日期: 2019-08-29

基金项目: 上海市教育发展基金会和上海市教育委员会“晨光计划”(18CGB09)

作者简介: 王晓红(1971—), 博士, 上海理工大学教授, 主要研究方向为数字图像处理与色彩管理。

在数字化媒体迅猛发展的今天,数字图像在人类获取和传递信息的过程中扮演着重要角色,但在图像的获取、传输、处理过程中,往往会由于运动、散焦、大气湍流等非理想因素导致图像模糊,不仅会造成图像质量下降,而且可能丢失信息,导致难以估量的损失。

数字图像的去模糊增强一直是图像处理领域的热门研究方向。当模糊类型和模糊核都已知时,采取有针对性的反卷积操作能够取得很好的效果,这类非盲去模糊的研究已经较为成熟。实际应用中,由于图像所受到的模糊损伤,其模糊过程和原始清晰图像信息都是未知的,就需要对模糊核进行准确而快速的计算,此时模糊核预测的精准性和算法复杂度成为图像去模糊的关键因素。目前常用的模糊核预估方法大多基于概率先验模型,韩阳^[1]采用两阶段恢复策略,首先在多尺度情况下利用图像稀疏性先验估计模糊核,再利用非盲反卷积求解清晰图像。Krishnan^[2]等提出基于归一化稀疏度量的图像盲去模糊算法,取得了不错的去模糊效果,但其运算复杂度较高,运行速度缓慢。徐弦秋等^[3]利用各个通道的色彩分量图所受到的模糊核影响的差异性,分 RGB 三颜色通道进行模糊核估计,提出一种获得更加精确的模糊核方法。

随着机器学习和人工智能的兴起,利用神经网络自学习的优点进行图像去模糊成为一种新的研究思路,Hradis 等^[4]提出基于 CNN 的图像去模糊方法,但是该方法只适用于文本的去模糊。Xu 等^[5]提出基于卷积神经网络(convolutional neural networks, CNN)的图像去模糊方法,针对图像的饱和区域易产生振铃效应的问题,采用 CNN 学习反卷积的过程,可用于图像任何类型的模糊移除,实用意义较大,但是去模糊的过程中丢失了图像的细节纹理信息。陈阳等^[6]提出一个基于自编码神经网络的深度学习框架,准确地标记出输入图像中的局部模糊区域,然后仅对这些区域进行去模糊处理,这样就能在有效去除局部模糊的同时不发生图像失真。Schuler 等^[7]在机器学习前进行图像预处理,首先在傅里叶域上进行图像模糊的反过程,然后使用多层感知机神经网络进行训练,虽然可以使图像清晰,但预处理的过程会放大噪声且容易产生振铃效应。文献[8]首先对高频图像进行傅里叶域上的预处理,然后以处理后图像小块及对应清晰图形小块作为输入和标签进行训练,设计了一种高频信号保持且可快速去模糊的快速 CNN 模型(FCNN),该方法可以加快计算效率但在细节部分的恢复效果还有待加强。文献[9]针对运动模糊提出一种基于条件生成对抗网络的盲去模糊算法,不仅保留了更多的纹理细节,也使得运行效率大幅提高。Ramakrishnan 等^[10]在生成对抗网络的基础上添加稀疏连接和稠密连接,在估计模糊核的过程中极大地减

少了测试时间。

针对现有图像去模糊方法高频纹理信息丢失及易产生振铃效应的问题。文中提出的图像去模糊方法具有 3 个方面的特点:将数字图像转换到 YUV 颜色空间中,仅在 Y 通道内进行去模糊操作,在保证去模糊效果的同时可以加快运算效率;文中探究无参考图像质量评价分数与模糊核尺寸之间的关系并用以预估反卷积核尺寸,在这个过程中,提出辨别率(distinguish rate, DR)作为无参考图像质量评价的新指标;提出一种两阶段自适应图像去模糊算法,根据图像的模糊程度使用不同的去模糊方式(SDYCNN),并针对去模糊过程中常见的振铃效应进行了优化处理。

1 相关工作

1.1 YUV 颜色空间

通常对于数字图像的存储、传输和处理过程都是在 RGB 颜色空间中进行的,但由于 RGB 颜色空间中红、绿、蓝三颜色通道之间存在着强相关性,任一通道的变化都会引起其他两通道的改变,这对于分通道去模糊操作将会产生消极影响。文献[3]中的研究结果也表明,图像发生模糊时,RGB 三通道的模糊核轮廓无论是形状还是值的分布都存在差异,忽略这一差异使用同一模糊核进行图像去模糊处理将会对图像复原的精准性产生影响。

与 RGB 颜色空间相比,YUV 颜色空间的优势在于将数字图像的颜色信息与灰度信息分开,由明度信息和色度信息共同表示,“Y”表示明亮度(灰阶值);而“U”和“V”表示的则是色度,作用是描述图像的色彩及饱和度,其中,U 反映了信号红色部分与蓝色部分之间的差异,V 反映的是黄色部分与绿色之间的差异。文中通过前期实验发现,图像被转换到 YUV 颜色空间后,模糊对图像失真的主要影响集中于 Y 通道,U,V 通道受模糊影响较小,结果见图 1。文中算法在对图像进行处理时,仅对人眼最为敏感的 Y 通道进行处理,不仅提高了运行效率,且保证了颜色的忠实性。

为验证不同颜色空间对图像去模糊效果的影响,以 FISTA^[11],FGISA^[12],SRCNN^[13]和 FCNN 等算法为基础,分别在 RGB 三通道、YUV 三通道和单独在 Y 通道进行去模糊处理,使用峰值信噪比(PSNR)和处理时间分别作为处理性能和计算效率的评价指标。其中,FISTA 和 FGISA 算法是以正则化为基础的传统去模糊方法,SRCNN 主要用以超分辨率重构,同时对于图像去模糊问题也能取得很好的效果。通过实验对 25 幅模糊图像进行处理并取平均值作为最终结果,见表 1。基于 YUV 颜色空间的去模糊方法在




图 1 清晰图与模糊图 YUV 分量对比

Fig.1 Comparison of YUV component in clear image and blur image

表 1 不同颜色空间去模糊效果比较
Tab.1 Comparison of deblurring effect in different color space

算法	峰值信噪比/dB			运行时间/s		
	RGB	YUV	Y	RGB	YUV	Y
FISTA	24.73	30.20	27.39	83.02	72.35	51.23
FGISA	25.64	31.69	28.64	76.85	68.53	49.61
SRCNN	22.56	30.85	30.02	52.24	44.55	21.63
FCNN	31.32	35.58	33.45	26.35	22.76	13.99

处理性能和计算效率都优于基于 RGB 颜色空间的去模糊算法, 仅在 Y 通道进行去模糊处理虽然在处理效果上略逊于基于 YUV 三通道的去模糊处理, 但在计算效率上却大大提升。在实际运用中, 由于视觉宽容性的存在, 处理效果上轻微的差异并不影响人眼观察结果。文中在进行去模糊处理时, 将数字图像转换到 YUV 颜色空间中, 仅在 Y 通道进行处理。

1.2 图像质量评价方法

图像质量评价方法的目的是获取与人眼视觉特征尽可能一致的质量评价结果, 质量分数可以反映图像的失真程度。对于模糊图像而言, 模糊核尺寸越大, 图像模糊失真程度越明显, 图像质量评价分数越低, 因此文中尝试使用图像评价的结果预测图像模糊核尺寸。为选择选择合适的图像质量评价方法, 文中通过实验比较了 PSNR, SSIM, BIQI^[14], BRISQE^[15], SSEQ^[16]等 5 种典型的图像质量方法来。PSNR 和结

构相似度 (SSIM) 被广泛地用于图像处理中, 但与人眼视觉特征的匹配性较差, BIQI, BRISQE 和 SSEQ 3 种算法是近年来提出的应用较为普遍的无参考图像质量评价方法 (NR-IQA)。

为衡量这 5 种图像质量评价方法, 文中使用 Spearman 秩序相关系数 (spearman rank order correlation coefficient, SROCC)、Pearson 线性相关系数 (Pearson linear correlation coefficient, PLCC)、均方根误差 (root mean squared error, RMSE) 和 DR 作为衡量指标, 比较结果见表 2。在这 4 项指标中, SROCC 主要评价的是 2 组数据的等级相关性, SRPCC 越高 (越接近于 1) 表明 2 个变量之间的等级相关性越高; PLCC 可以评价 2 组数据的线性相关关系, 若其绝对值接近于 1, 则其之间的关系就可以用一个线性直线方程来表示; RMSE 表示均方误差的算术平方根, 其值越小, 说明评价模型描述数据具有更好的精确度; DR 表示模糊程度能被准确区分的概率, 对于模糊核的准确预测具有十分重要的作用, DR 的计算见式 (1)。

$$D_R = \frac{X_i}{\sum_{i=1}^n X_i} \times 100\% \quad (1)$$

式中: X_i 为模糊图像的数量; $\sum_{i=1}^n X_i$ 为图像总共的数量。

从表 2 可以看出, SSEQ 算法与其他评价方法相比, 尽管 SROCC 和 PLCC 指数略低于 BRISQUE,

但也处于较高的水平；同时，SSEQ 在 RMSE 和 DR 这 2 个指标的得分都处于最佳水平，表示 SSEQ 算法在预测精准性和对模糊图像的区分度方面都有十分优异的表现，因此，文中使用 SSEQ 探究不同模糊程度的特征，并根据评价分数结果预估图像模糊核尺寸。SSEQ 评价分数与不同模糊核尺寸之间的对应关系见图 2，其中，横坐标表示 15 幅不同的模糊样本图像，纵坐标表示对应的 SSEQ 分数，每幅样本图像包含 5×5，7×7，9×9，11×11 等 4 种不同的模糊核尺寸。从图 3 中可以看出，对于高斯模糊而言，当模糊核尺寸为 11×11 时，对应模糊图像的 SSEQ 分数分布在 30~40 之间；当模糊核尺寸为 9×9 时，对应模糊图像的 SSEQ 分数分布在 40~50 之间；当模糊核尺寸为 7×7 时，对应模糊图像的 SSEQ 分数在大约在 50~55 之间；当模糊核尺寸为 5×5 时，对应模糊图像的 SSEQ 分数在大约在 55~60 之间。由此可以得出，不同模糊核尺寸对应的 SSEQ 分数之间具有明显的分层现象，可以根据 SSEQ 的分数推断出图像的模糊核尺寸。

1.3 反卷积

从数学角度来看，图像模糊可以用图像经过点扩散函数的卷积过程描述，即清晰图像 x 经过模糊核 k 的卷积，同时添加噪声 n ，得到模糊图像 y ，见式(2)。

$$y = x * k + n$$

式中：*为卷积操作。

表 2 不同图像质量评价方法效果比较
Tab.2 Comparison of effects of different image quality assessment methods

图像质量算法	SROCC	PLCC	RMSE	DR/%
PSNR	0.8293	0.8081	9.4973	51.14
SSIM	0.8996	0.9100	6.6335	53.41
BIQI	0.7599	0.7422	15.9547	89.13
BRISQUE	0.9368	0.9365	8.3295	94.57
SSEQ	0.9265	0.9177	6.3943	97.73




图 2 不同模糊核尺寸对应的 SSEQ 分数
Fig.2 SSEQ scores corresponding to different blur kernel sizes

图像去模糊的过程可以看作图像模糊的逆过程，即对模糊图像进行反卷积，根据模糊图像 y 与核函数 k ，求解潜在清晰图像 x ，此过程见式(3)。

$$y = \arg \min \|y - x * k\|^2 + r(x)$$

(3)

式中： $\|y - x * k\|$ 表示模糊图像与原始图像的相似度； $r(x)$ 为约束项，表示图像先验知识。

在实际应用中，图像的模糊是一个复杂且未知的过程，不仅模糊核未知，存在多种模糊并存的情况，模糊过程远比式(1)的模型复杂，为简化运算，通常将模糊过程简化为卷积过程，此时图像去模糊的关键在于反卷积核的精准确定。根据 2.2 节中的实验结果，可以建立模糊核尺寸核 SSEQ 分数之间的对应关系，从而进一步预估反卷积核的尺寸。

1.4 CNN

鉴于图像去模糊过程中模糊图像与清晰图像之间的复杂性，通过人工规则建立确切的数学模型较为困难。尤其是随着图像模糊程度的增加，仅仅通过反卷积已经难以取得令人满意的去模糊效果，因此，将机器学习用于图像的去模糊方法成为近年来新的研究方向。通过构建具有很多隐层的机器学习模型和海量的训练数据，学习更内在的特征和映射关系，其中最为典型的是基于 CNN 的图像去模糊算法。

CNN 模型在自学习和参数优化等方面具备独特的优势，基于 CNN 增强的图像去模糊方法包括 2 种基本思路：一种思路是利用 CNN 学习反卷积的过程，估测出未知的模糊核^[17]；另一种是通过端到端的训练建立模糊图像与清晰图像之间的映射关系，直接进行去模糊增强^[18]。基于 CNN 的图像去模糊方法能够克服许多传统数学方法难以解决的非线性问题，取得很好的去模糊效果，但在训练过程中涉及大量参数的优化调整，计算时间长，复杂度高。此外，现有的深度学习模型大多直接使用模糊图像和清晰图像作为训练对，输入与输出之间巨大的差异使得特征的提取较为困难，通过对输入图像进行增强有助于特征的准确提取。

2 基于 YUV 颜色空间的自适应图像深度去模糊方法 (SDYCNN)

2.1 算法框架

文中基于 Y 通道反卷积和卷积神经网络提出一种两阶段自适应图像去模糊算法，算法框架见图 3。在第 1 阶段，首先利用 SSEQ 对模糊图像进行质量评价，根据 SSEQ 质量分数判断图像失真程度并推测出模糊核尺寸，同时将数字图像转换至 YUV 颜色空间^[19]，在 Y 通道内进行反卷积增强；在第 2 阶段，根据第 1 阶段模糊等级判断结果，利用 CNN 模型对

严重模糊图像反卷积增强后的图像进行深度去模糊处理,然后转换至 RGB 颜色空间,得到去噪增强后图像。

2.2 两阶段自适应去模糊算法

模糊程度较低的图像信息丢失少,信息保留多,恢复相对容易;对于模糊程度较高的图像,图像高频细节丢失严重,源图像信息保留较少,图像恢复难度大。文中根据模糊程度不同设计两阶段去模糊算法,对于模糊程度较低的图像,第 1 阶段使用自适应反卷积的方式足以产生良好效果,对于模糊程度较高的图像,则需通过第 2 阶段基于 Y 通道的 CNN 模型进行进一步处理。

2.2.1 第 1 阶段

在第 1 阶段,通过计算模糊图像的 SSEQ 分数来判断图像的失真等级并预估模糊核尺寸,将图像分为轻微失真图像与严重失真图像 2 类(文中实验时选择当 SSEQ 分数大于等于 55 分时为轻微失真,否则判

断为严重失真),同时将输入图像转换至 YUV 颜色空间中,在 Y 通道内使用反卷积去模糊处理,针对反卷积去模糊中容易出现的振铃效应,采用边界扩展配合权重矩阵的方法进行规避,即将图像边界的尺寸加大一个模糊核宽度,加宽部分的像素是对原图像最外一层的镜像复制。这样等图像重构完成以后,再将其去除一个模糊核尺寸,就能解决边缘振铃效应。实验结果表明,轻微模糊图像在第 1 阶段已经能够取得很好的去模糊效果,但对于模糊较为严重的图像处理效果较差。

2.2.2 第 2 阶段

在第 2 阶段,反卷积增强后的轻微模糊图像被直接转换至 RGB 颜色空间作为去模糊图像输入;对于严重模糊图像,第 1 阶段的反卷积增强仅作为预处理,通过 CNN 模型进行进一步深度去模糊处理,目前基于 CNN 的去模糊模型都直接使用模糊图像和对应的清晰图像作为输入和标签进行训练,由于模糊图像和清晰图像间存在较大差异,潜在特征难以提取,




图 3 文中算法流程

Fig.3 Flowchart of the proposed algorithm

导致训练结果较差。文中 CNN 模型在训练时使用反卷积增强后的图像与清晰图像作为图像对进行端到端的训练,建立反卷积处理后图像与清晰图像的对应关系,在保证运算效率的同时改善了处理效果。针对灰度反差较大的区域容易出现的振铃效应现象,文中以 SSEQ 分数作为阈值,对图像进行分块迭代处理。

算法中的自适应性主要体现在 3 个方面:根据图像模糊程度决定第 2 阶段是否需要通过神经网络进行去模糊处理,在保证处理结果视觉效果的同时加快了计算效率;反卷积核尺寸根据模糊图像质量评价分数决定;反卷积过程中的梯度权重矩阵和边界尺寸根据模糊程度自适应决定,有利于去除振铃效应。

2.3 CNN 训练过程

基于 CNN 进行去模糊直观方法是将模糊图像块直接作为网络模型的输入,对应的清晰图像块作为标签进行训练,得到复杂的映射函数,并用于图像的模糊去除中。大量实验表明,这一思路得到的去模糊结果较差。产生这种现象的主要原因是直接应用 CNN 去除模糊只考虑图像的先验特征,容易受到其他因素的影响。模糊程度较为严重的图像先验特征采集困难,导致最终很难获得清晰的去模糊图像,因此文中提出 CNN 模型与反卷积增强相结合的模糊去除方法,利用反卷积对模糊图像进行增强,得到一个较为清晰、鲁棒性较强的初始值,作为卷积神经网络模型的输入,然后进行模型训练,最终得到清晰图像。实验验证,图像经过反卷积处理后,清晰度显著提高,将其作为深度学习的输入,模型收敛速度快、效率高。

文中使用多层 CNN 模型进行训练,网络结构见图 4。文中使用的卷积神经网络由 4 个卷积层组成,卷积层的通道数分别为[128, 64, 32, 16],核尺寸分别为[3, 3, 3, 1],步长分别为[1, 1, 1, 1],相邻卷积层之间通过 PRelu 激活函数^[20]和批规范化层(BN)进行连接。以反卷积增强后的模糊图像作为输入,输入图像块尺寸为 33×33,标签为对应的清晰图像,尺寸为 21×21。卷积层^[21]主要用于图像信息特征的获取,利用卷积神经网络局部连接,全局共享的优势,减少网络训练过程中大量的学习参数;每一层

的输出作为下一层的输入,卷积层的特征图可能与前一层的若干特征图建立关系,在一幅图像的不同位置使用同一套连接参数。这样的连接方式能够充分考虑图像的局部密切相关特性与统计特性,与视觉系统中局部感受也相契合,同时还减少了参数数量与连接数目。

影响 CNN 训练效果的因素包括卷积层数、激活函数、池化方式等,其中最重要的是卷积层数的选择。卷积层越多,网络结构越复杂,参数越多。一般而言,卷积层数的增加有助于图像中潜在特征的提取,但若卷积层过多,学习特征太过抽象复杂,计算效率降低甚至可能出现过拟合。在卷积层数的选择与确定方面,文中以峰值信噪比(PSNR)为评价指标,通过实验验证网络层数对恢复效果的影响。以模糊核大小为 9×9 的图像模糊等级为例,不同卷积层数图像恢复效果实验结果见图 5。由图 5 中可以看出,在文中实验中,4 层的卷积神经网络可以对模糊图像获得一个质量较好且较为稳定的恢复数据,因此文中选用 4 层的卷积神经网络进行图像恢复。

CNN 模型中另一个重要参数是激活函数,文中在开展实验时选择 PRelu 函数作为激活函数。PRelu 函数是 Relu 函数的变体,由于 ReLU 激活函数具有计算效率高、收敛性强、生理学上的合理性等优点,在神经网络中被广泛应用。ReLU 函数的特点是强制非负校正函数,即对于输入值为负时不进行映射输出,因此在输入为负值时梯度为零容易产生梯度消失,输入均为正时梯度又会向固定的方向变化,这种非对称的输出对于初始化有很高的要求。近年来,针对 ReLU 函数产生了许多优化变体,其中最为典型和普遍使用的是 Leaky ReLU 函数,该函数通过在负数区域内设置一个很小的斜率 a ,这样可以避免 ReLU 梯度消失的问题。PRelu 在 Leaky ReLU 的基础上继续进行改进,负值部分的斜率是根据数据来确定的,而非预先定义的。

2.4 振铃效应优化算法

经过深度学习恢复的图像获得了较好的视觉效果,但在图像灰度反差大区域,出现恢复图像的纹理不规则现象(振铃效应)。文中使用基于图像块分割的迭代运算进行优化。首先利用 SSEQ 算法对经文中




图 4 文中 CNN 网络架构

Fig.4 Proposed CNN structure




图 5 不同卷积层数的恢复效果

Fig.5 Restoration effect of different convolutional layers

算法处理后的图像进行评分,对评分结果低于设定阈值(文中进行实验时,阈值设定为 50,从图 2 中可以看出,当图像的 SSEQ 分数低于 50 时,对应模糊核尺寸较大,说明此时图像模糊较严重)的图像使用 CNN 模型进行进步去模糊处理,对相邻 2 次输出图像分别进行分块,分别计算 2 次结果对应图像块的 SSEQ 分数。数值低于设定阈值的取后一次恢复小块替代前一次恢复图像块,高于则不变,反复迭代直至整幅图像的 SSEQ 评分结果高于设定值为止,从而完成图像振铃区域修复。算法流程见图 6,经过振铃效应修复算法后的图像效果见图 7。




图 6 振铃效应修复算法流程

Fig.6 Restoration algorithm flowchart of ringing effect

3 实验结果

文中算法效果采用 Matlab 语言实现,网络模型训练时采用基于 CPU 的 caffe 框架,所用的计算机配置为 Windows 7 专业版,16 GRAM,NVIDIA Quadro 2000。将反卷积预处理得到的图像作为快速高效模糊去除的 CNN 模型的输入样本,对应的清晰图像作为标签,训练 CNN 模型。实验时采用 TID 2008 作为图像数据库,按照文献[20]中的方法对数据进行增强,通过随机旋转的方式对每张原图生成 12 张不同的转换图像,这样将训练数据集由原来的 1700 张扩充至 22 100 张,选取数据集的 70%作为训练集,15%作为测试集,15%作为验证集。实验结果见表 3—5。

表 3—5 中分别展示了去模糊后图像的 SSEQ 评价得分、PSNR 值和 SSIM 值,可以明显看出文中算法恢复质量较高,取得了良好的去模糊效果,视觉效果见图 8。

为验证文中算法的性能,通过实验将文中算法与 FISTA 算法^[21]、FGISA 算法^[22]、SRCNN 算法进行比较。常用的传统去模糊方法是对该问题进行正则化,FISTA 算法是求解 l_1 正则化的重要算法,FGISA 算法是基于 l_p 范数约束的图像去模糊快速广义迭代收缩算法,二者是传统方式去模糊领域较为典型的算法;SRCNN 是深度学习用在超分辨率重建上的开山之



图 7 实验效果展示
Fig.7 Exhibition of experiment effect

表 3 模糊等级一评价参数（模糊核：5×5）
Tab.3 Experimental results for kernel size 5×5

图像编号	SSEQ_mohu	SSEQ_huifu	PSNR	SSIM
1	44.55	13.2	40.59	0.99
2	46.82	10.91	44.01	1
3	42.59	11.56	42.36	0.99
4	45.43	9.73	42.65	0.99
5	46.98	8.04	40.95	0.99
6	46.79	11.83	42.72	0.99
7	48.28	7.28	43.01	0.99
8	44.88	6.79	40.88	0.99
9	41.47	11.62	41.13	0.99
10	43.03	9.6	42.05	0.99

表 4 模糊等级二评价参数（模糊核：7×7）
Tab.4 Experimental results for kernel size 7×7

图像编号	SSEQ_mohu	SSEQ_huifu	PSNR	SSIM
1	51.92	20.39	36.45	0.99
2	53.82	10.7	41.38	0.99
3	50.14	16.32	38.73	0.99
4	51.87	15.12	39.37	0.99
5	55.41	15.38	35.02	0.97
6	53.21	16.19	39.07	0.99
7	54.01	14.7	32.64	0.93
8	54.53	12.17	34.66	0.98
9	48.86	15.62	37.4	0.99
10	51.78	15.12	37.95	0.99

作，在图像去模糊方面也具有良好的效果，文中以峰值信噪比 PSNR 与处理时间作为评价指标进行比较，比较结果见表 6。由表 6 可以看出，文中所提出的算

法，不仅在恢复效果上有明显提升，而且由于转换了颜色空间，仅在 Y 通道上进行图像去模糊操作，运行效率得到极大提高。

表 5 模糊等级三评价参数 (模糊核: 9×9)
Tab.5 Experimental results for kernel size 9×9

图像编号	SSEQ_mohu	SSEQ_huifu	PSNR	SSIM
1	60.51	23.88	33.4	0.97
2	59.8	29.33	36.66	0.98
3	56.66	26.28	33.94	0.95
4	58.27	26.79	34.69	0.95
5	62.25	24.6	33.64	0.96
6	59.33	27.23	34.81	0.95
7	59.22	25.9	33.33	0.92
8	61.18	23.84	32.25	0.96
9	55.36	24.21	33.78	0.97
10	59.09	25.08	33.83	0.96

表 6 不同算法去模糊结果比较 (模糊核: 9×9)
Tab.6 Comparison of deblurring effects of different algorithms (blur kernel: 9×9)

评价结果	峰值信噪比 PSNR/ dB				处理时间/ s			
	FISTA	FGISA	SRCNN	文中算法	FISTA	FGISA	SRCNN	文中算法
最大值	30.20	31.69	31.25	35.58	83	82	25.74	26
最小值	24.73	25.64	27.95	31.32	51	63	20.36	13
中值	27.39	28.64	30.75	33.45	72	64	22.89	15
平均值	27.94	28.57	29.11	33.38	68.67	69.67	23.00	18



图 8 模糊失真图像恢复图

Fig.8 Blurred distortion images after restoration

4 结语

文中通过实验确定了模糊核尺寸与 SSEQ 质量评价分数的关系,并将其应用于反卷积核尺寸的自适应预估中;在进行去模糊操作时,首先将图像转换至 YUV 颜色空间,在 Y 通道内进行去模糊处理;最终文中基于反卷积增强和卷积神经网络提出一种两阶段自适应图像模糊算法,对于模糊程度较轻的图像,自适应的选定模糊核尺寸,直接进行反卷积增强实现

去模糊,对于模糊程度较严重的图像,进一步通过卷积神经网络建立反卷积增强后的模糊图像与高质量图像的对应关系,并基于此关系进行去模糊。实验证明该算法可以实现对模糊程度不同图像的自适应恢复,不仅取得了很好的去模糊效果,而且运行效率也得到显著提升。

参考文献:

[1] 韩阳. 两阶段反卷积图像去模糊算法的 DSP 实现

- [D]. 武汉：华中科技大学，2016：1—20.
HAN Yang. DSP Implementation of Two-phase Deconvolution Image Deblurring Algorithm[D]. Wuhan: Huazhong University of Science and Technology, 2016: 1—20.
- [2] KRISHNAN D, TAY T, FERGUS R. Blind Deconvolution Using a Normalized Sparsity Measure[C]// Computer Vision and Pattern Recognition, IEEE, 2011: 233—240.
- [3] 徐弦秋, 刘宏清, 黎勇, 等. 基于 RGB 通道下模糊核估计的图像去模糊[J]. 重庆邮电大学学报(自然科学版), 2018, 30(2): 216—221.
XU Xian-qiu, LIU Hong-qing, LI Yong, et al. Image Deblurring with Blur Kernel Estimation in RGB Channels[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2018, 30(2): 216—221.
- [4] HRADIS M, KOTERA J, ZEMČÍK P, et al. Convolutional Neural Networks for Direct Text Deblurring[C]// British Machine Vision Conference, 2015: 1—10.
- [5] XU L, REN J S J, LIU C, et al. Deep Convolutional Neural Network for Image Deconvolution[C]// International Conference on Neural Information Processing Systems, MIT Press, 2014: 1790—1798.
- [6] 陈阳, 周圆. 一种基于深度学习模型的图像模糊自动分析处理算法[J]. 小型微型计算机系统, 2018, 39(3): 584—590.
CHEN Yang, ZHOU Yuan. Automatic Analysis and Processing of Image Blur Using Deep Learning[J]. Journal of Chinese Computer Systems, 2018, 39(3): 584—590.
- [7] SCHULER C J, BURGER H C, HARMELING S, et al. A Machine Learning Approach for Non-blind Image Deconvolution[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos: IEEE Computer Society Press, 2013: 1067—1074.
- [8] 任静静, 方贤勇, 陈尚文, 等. 基于快速卷积神经网络的图像去模糊[J]. 计算机辅助设计与图形学学报, 2017, 29(8): 1444—1456.
REN Jing-jing, FANG Xian-yong, CHEN Shang-wen, et al. Image Deblurring Based on Fast Convolutional Neural Networks[J]. Journal of Computer-aided Design and Computer Graphics, 2017, 29(8): 1444—1456.
- [9] OREST K, VOLODYMYR B, MYKOLA M, et al. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks[C]// IEEE CVF Conference on Computer Vision and Pattern Recognition, 2018: 18—23.
- [10] RAMAKRISHNAN S, PACHORI S, GANGOPADHYAY A, et al. Deep Generative filter for Motion Deblurring[C]// IEEE International Conference on Computer Vision Workshops (ICCVW), 2017: 22—29.
- [11] ZUO W M, REN D W, ZHANG D, et al. Learning Iteration Wise Generalized Shrinkage-thresholding Operators for Blind Deconvolution[J]. IEEE Transactions on Image Processing, 2016, 25(4): 1751—1764.
- [12] 王鹏, 段鹏飞, 熊盛武. 基于 l_p 正则化图像去模糊的快速广义迭代收缩算法[J]. 武汉大学学报(理学版), 2017, 63(6): 551—556.
WANG Peng, DUAN Peng-fei, XIONG Sheng-wu. Image Deblurring via Fast Generalized Iterative Shrinkage Thresholding Algorithm for l_p Regularization[J]. Journal of Wuhan University (Natural Science Edition), 2017, 63(6): 551—556.
- [13] DONG C, LOY C C, HE K, et al. Image Super-Resolution Using Deep Convolutional Networks[J]. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2016, 38(2): 295—307.
- [14] MOORTHY A K, BOVIK A C. A Two-step Framework for Constructing Blind Image Quality Indices[J]. IEEE Signal Processing Letters, 2010, 17(2): 513—516.
- [15] MITTAL A, MOORTHY A K, BOVIK A C. No-reference Image Quality Assessment in the Spatial Domain[J]. IEEE Transactions on Image Processing, 2012, 21(12): 4695—4708.
- [16] LIU L, LIU B, HUANG H, et al. No-reference Image Quality Assessment Based on Spatial and Spectral Entropies[J]. Signal Processing: Image Communication, 2014, 29(8): 856—863.
- [17] SUN J, CAO W, XU Z, et al. Learning a Convolutional Neural Network for Non-uniform Motion Blur Removal[C]// Computer Vision and Pattern Recognition (CVPR), 2015: 7—12.
- [18] GONG D, YANG J, LIU L, et al. From Motion Blur to Motion Flow: a Deep Learning Solution for Removing Heterogeneous Motion Blur[C]// Computer Vision and Pattern Recognition (CVPR), 2017: 21—26.
- [19] ZHANG X, YANG L, CUI S, et al. YUV-based Material Modeling from a Single Image[C]// International Congress on Image and Signal Processing, Biomedical Engineering and Informatics, IEEE, 2017: 15—17.
- [20] DOMONKOS V, DIETMAR S, TAMÁS S. DeepRN: A Content Preserving Deep Architecture for Blind Image Quality Assessment[C]// 2018 IEEE International Conference on Multimedia and Expo (ICME), 2018: 23—27.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Delving Deep into Rectifiers: Surpassing Human-level Performance on Image Net Classification[C]// IEEE International Conference on Computer Vision (ICCV), 2015: 7—13.
- [22] ZHANG J, PAN J, LAI W S, et al. Learning Fully Convolutional Networks for Iterative Non-blind Deconvolution[C]// IEEE Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, 2017: 21—26.