

基于改进 Retinex 与双 CNNs 的钢轨表面缺陷图像 增强算法研究 *

罗晖 章硕生 曾伟 张金华

(华东交通大学信息与软件工程学院 南昌 330013)

摘要: 在钢轨表面缺陷检测过程中,受光照不均、镜头抖动等外界因素的影响,采集的图像存在对比度低、背景不均匀和缺陷细节模糊等问题。为此,提出一种基于改进 Retinex 与双 CNNs 的钢轨表面缺陷图像增强算法。首先,将钢轨表面缺陷 RGB 图像转换为 HSV 空间后,采用引入均值和均方差,加入控制图像动态参数的 Retinex 算法,实现 V 分量对比度的调整,再通过自适应伽马变换校正图像曝光;其次,对 S 分量根据亮度进行自适应非线性增强,解决光照变化带来的背景不均匀问题;然后,为了进一步解决镜头抖动产生的缺陷图像细节模糊问题,设计了基于 U-Net 结构的去模糊子网络和超分辨率细节恢复子网络组成的双 CNNs 网络,学习原始图像和增强后图像的语义特征,并提取其纹理特征,以获取高质量图像的纹理和细节信息。最后,采用 RSDDs 数据集和自制钢轨表面缺陷模糊图像数据集对模型进行训练和测试。实验结果表明,与现有的主流算法相比,峰值信噪比和结构相似性分别提高了 2.61 dB 和 0.026,在视觉上较另外 10 种方法获得的钢轨表面缺陷图像具有较高的对比度、清晰的缺陷细节和丰富的纹理信息。

关键词: 钢轨表面缺陷;HSV;改进 Retinex;图像增强;双 CNNs;去模糊

中图分类号: TN391.41; U216.3 文献标识码: A 国家标准学科分类代码: 510.99

Research on image enhancement algorithm of rail surface defects based on improved Retinex and dual CNNs

Luo Hui Zhang Shuosheng Zeng Wei Zhang Jinhua

(School of Information and Software Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: In the process of rail surface defect detection, due to the influence of external factors such as uneven illumination and lens shake, the collected images have problems such as low contrast, uneven background and blurred defect details. Therefore, an image enhancement algorithm for rail surface defects based on improved Retinex and dual CNNs was proposed. Firstly, after converting the RGB image of rail surface defects into HSV space, the Retinex algorithm that introduces the mean and mean square deviation and controls the dynamic parameters of the image is added to adjust the contrast of the V component, and then the image exposure is corrected by adaptive gamma transform. Secondly, the S component is enhanced according to the brightness to solve the problem of uneven background caused by lighting changes. Thirdly, in order to further solve the problem of blurring the details of defective images caused by lens shake, a dual CNNs network composed of a deblurring sub-network and a super-resolution detail recovery sub-network based on U-Net structure was designed to learn the semantic features of the original image and the enhanced image, and extract their texture features to obtain the texture and detail information of high-quality images. Finally, the RSDDs dataset and the self-made rail surface defect fuzzy image dataset were used to train and test the model. Experimental results show that compared with the existing mainstream algorithms, peak signal-to-noise ratio and structural similarity are increased by 2.61 dB and 0.026, respectively, and visually have higher contrast, clear defect details and rich texture information than the rail surface defect images obtained by the other 10 methods.

Keywords: rail surface defect; HSV; improved Retinex; image enhancement; dual CNNs; deblurring

0 引言

磨损等接触应力和自然风化的影响,其表面易出现裂纹、疤痕、磨损等缺陷,随着时间的推移,这些缺陷将进一步恶化钢轨表面质量。据统计,由钢轨表面缺陷引起的列车安全

钢轨作为铁路运输中的重要部件,受轮轨挤压、冲击、

事故约占全部事故的 30%^[1]。为确保铁路的安全运营,实现对钢轨表面缺陷的高效、精确检测,图像处理的方法在钢轨表面缺陷检测领域应用越来越广泛^[2]。在采集钢轨表面图像过程中,受光照变化、纹理背景杂波以及拍摄过程中镜头抖动的影响,导致获取的钢轨表面缺陷图像往往存在对比度低、背景不均匀、缺陷细节模糊等问题,这对钢轨表面缺陷检测和识别带来重大挑战。

针对钢轨表面缺陷图像的对比度低和背景不均匀的问题,王伟江等^[3]提出一种融合卡通纹理分解和最优双曲正切曲线的图像增强方法,增强了图像对比度和细节信息,但在极暗条件下,增强后的图像视觉效果不佳;何磊等^[4]提出一种基于 Retinex 先验引导的低光照图像快速增强方法,将 Retinex 模型与 Gamma 校正相结合,输出对比度高、视觉效果好和噪声低的图像,但该方法没有考虑光照条件的变化;罗晖等^[5]通过采用改进 Retinex 算法增强了缺陷与背景的对比度,解决钢轨表面缺陷图像背景不均匀的问题。

然而,现有的图像增强方法没有考虑镜头抖动带来的钢轨表面缺陷图像细节模糊的问题。为此,侯庆璐等^[6]提出了一种结构稀疏通道先验(structurally sparse channel prior,SSCP)盲图像去模糊方法,该方法利用 SSCP 作为新正则化项构建盲去模糊新模型,实现对模糊核的估计,但该方法在面对不同复杂程度的模糊图像上表现不佳,因此,在获得更好去模糊效果的基础上提高算法的鲁棒性方法逐渐被提出;孙妍等^[7]提出了一种基于 L1 正则化二阶梯度的暗通道先验盲图像去模糊算法,利用二阶梯度随图像变模糊而减小特点,对其添加范数约束,并引入暗通道先验,同时采用半二次分裂输出清晰图像和模糊核。随着深度学习的发展,基于深度学习的图像去模糊方法相继提出。Lim 等^[8]设计一种深度频谱-空间网络,该网络采用编码器-解码器网络相级联的方法,通过学习频谱和空间特征来恢复清晰的图像,但边缘细节不清晰,视觉效果方面不好;因此,孙晶晶等^[9]提出了一种基于 DeblurGAN 的运动模糊图像盲复原方法,以解决图像边缘细节恢复不足以及鲁棒性不高的问题。近年来,相关研究逐渐关注联合解决图像增强及去模糊问题,如 Li 等^[10]提出了一种自监督归一化流(self-supervised normalizing flow,SSFlow)的方法,SSFlow 由正交通道注意力模块和归一化流两个模块组成,在 SSFlow 的训练过程中,以低光模糊图像作为输入,在编码器中融入正交通道注意力块,提高整个网络的表征能力,解码器则集成了滤波器自适应卷积层,实现有效图像去模糊;Zhang 等^[11]设计了一种图像特征空间维纳反卷积网络,用于低光条件下非盲图像去模糊,通过在频率空间中结合模型驱动和数据驱动的正则化方法,解决低光照条件下的复杂噪声和伪影问题,实现了高质量夜间图像去模糊。然而,这些方法在面对光照条件变化下的钢轨表面图像处理效果不理想,且没有考虑图像的细节恢复,导致去模糊后的图像细节纹理丢失。

针对上述问题,本文提出一种基于改进 Retinex 与双 CNNs 的钢轨表面缺陷图像增强研究方法。该方法在传统 Retinex 算法的基础上引入均值和均方差,加入控制图像动态参数,以增强钢轨表面缺陷边缘信息和提高缺陷与背景的对比度,同时利用 HSV 空间中的 S 分量对光照不敏感的特点,对其进行自适应非线性增强,解决光照不均带来的背景不均匀的问题。为进一步解决增强后的钢轨表面缺陷图像存在缺陷细节模糊和纹理信息丢失的问题,采用基于 U-Net 结构的去模糊子网络和超分辨率细节恢复子网络组成的双 CNNs 网络模型,增强细节恢复能力的同时提高图像清晰度。最后,在自制钢轨表面缺陷模糊图像数据集上的实验结果表明,所提方法展现了优秀的图像增强性能。

1 基于改进 Retinex 与双 CNNs 模型框架

由于在采集钢轨表面图像过程中容易受到光照条件变化和镜头抖动的干扰,导致钢轨表面缺陷图像对比度低、背景不均匀和缺陷细节模糊等问题,给钢轨表面缺陷检测和识别带来重大困难。为了更好地检测和识别钢轨表面缺陷,从钢轨表面区域提取、图像增强、图像去模糊 3 个步骤对钢轨表面缺陷图像进行处理,提高钢轨表面缺陷图像质量,整体模型框架如图 1 所示。

1.1 钢轨表面区域提取

在图像采集系统中,摄像机采集的钢轨表面区域图像中含有镇流器、扣件、枕木等部件。为了减少纹理背景对钢轨表面缺陷检测的影响,必须找到钢轨在图像中的位置并进行裁剪。因此,首先要对采集的图像进行预处理,本文通过采用柱直方图最小法^[12]从原始图像中分割出目标钢轨区域,算法步骤如下:

- 1) 计算各列 S_i 的灰度值之和。
- 2) 在固定轨宽间隔 d 下,求 $(S_{i+d} - th)$ 的最小值 \min 。
- 3) 最小值 \min 对应的第 i 列为对应钢轨的最左侧位置。
- 4) 最右侧钢轨位置为第 $i + d$ 列。

1.2 基于改进 Retinex 的钢轨图像增强算法

在图像采集过程中,容易受到光照变化和其他环境因素的影响,导致采集的钢轨表面图像出现对比度偏低和亮度不均匀的现象,影响了钢轨表面缺陷检测与识别的准确性。因此,对钢轨表面图像进行增强,突出缺陷信息是钢轨表面缺陷检测的关键前期处理。

HSV 空间比 RGB 色彩空间更符合人眼对颜色的感知,为避免在 RGB 色彩空间中分别调整 3 个颜色通道,将钢轨表面图像转换为 HSV 空间后,在保持 H 分量不变的情况下对 S 分量和 V 分量进行以下处理。

根据 Retinex 理论,图像 $I(x, y)$ 可以看作是由一个照射分量和一个反射分量组成的乘积,其关系式为:

$$I(x, y) = L(x, y) \cdot R(x, y) \quad (1)$$

式中: $L(x, y)$ 表示照射分量,描述了光源、拍摄环境的亮




图 1 整体模型框架

Fig. 1 Overall model frame

度等信息; $R(x, y)$ 表示反射分量, 反映物体的表面信息和物体的本质特征。

多尺度 Retinex(multi-scale retinex, MSR)^[13] 算法是在单尺度 Retinex(single scale retinex, SSR) 算法的基础上提出的, 通过对多个尺度进行加权平均取值以获得更好的结果, 其表达式如下:

$$R_{MSR}(x, y) = \sum_{n=1}^N W_n \{ \log[I(x, y)] - \log[I(x, y) \cdot G_n(x, y)] \} \quad (2)$$

式中: N 为尺度总数, 一般取 3, W_n 表示高斯函数的尺度数, $G_n(x, y)$ 表示带有尺度数的高斯放大器。

MSR 算法通过多尺度处理, 可以有效地提高图像的对比度和保留原始图像的颜色信息, 然而在提高对比度的过程中, 会导致阴影和高光区域之间的过渡变得不自然和纹理不清晰, 以及可能会放大图像暗部区域中的噪声, 影响图像的视觉效果。为了增强钢轨表面缺陷的边缘信息, 在 MSR 算法的基础上引入均值和均方差, 加入了控制图像动态的参数, 以实现对比度调整, 其表达式为:

$$R(x, y) = \frac{255}{2} \left(1 + \frac{\log[R_{MSR}(x, y) - \mu]}{D \times MSE} \right) \quad (3)$$

式中: D 为图像的动态调整参数, D 的值与图像的对比度成反比, μ 、 MSE 分别为 $\log[R_{MSR}(x, y)]$ 中 R 、 G 、 B 通道数的均值和均方差。经实验证, 当尺度数为 3, D 为 2.6 时, 图像增强效果最佳。

经过改进的 MSR 处理后, 对 V 分量图像 $R(x, y)$ 再

进行自适应伽马变换, 增强图像的暗部特征的同时校正图像的曝光, 自适应伽马变换的基本形式如下:

$$G(x, y) = [r(x, y)]^\gamma \quad (4)$$

$$\gamma = [2 + l(x, y)]^{[2 \times l(x, y) - 1]} \quad (5)$$

式中: $G(x, y)$ 是处理后的图像。 γ 控制整个变换的缩放程度, 当 $\gamma > 1$ 时, 高灰度级的像素值会相对增加, 而低灰度级的像素值则会相对减少; 当 $\gamma < 1$ 时, 低灰度级的像素值会相对增加, 高灰度级的像素值则会相对减少。 $l(x, y)$ 与 γ 正相关, 通过自适应伽马校正, 可以有效避免过亮区域的产生, 同时进一步增强较暗区域的亮度。

HSV 空间中的 S 分量代表其饱和度图像, 利用其对光照不敏感的特点来克服光照不均的干扰。在本研究中, 首先计算图像亮度分量增强因子, 饱和度根据亮度进行自适应调整, 其表达式定义如下:

$$\beta = \frac{V'}{V} \quad (6)$$

$$\beta' = \frac{\beta - \beta_{\min}}{\beta_{\max} - \beta_{\min}} \quad (7)$$

$$S' = \left[\frac{1}{2} + \beta' \times \frac{\max(R, G, B) + \min(R, G, B) + 1}{2 \times \text{mean}(R, G, B) + 1} \right] \times S \quad (8)$$

式中: β, β' 分别表示为亮度比和归一化亮度比, V 和 V' 分别为增强前后的亮度分量, S 和 S' 分别为调整前后的饱和分量。在原始图像中, $\max(R, G, B)$ 、 $\min(R, G, B)$ 和 $\text{mean}(R, G, B)$ 分别代表各自 RGB 通道相关像素的最大值、最小值和平均值。

1.3 基于双 CNNs 的钢轨图像去模糊算法

经过图像增强后,有效解决了光照不均导致钢轨表面缺陷图像对比度低和背景不均匀的问题,但增强后的钢轨表面缺陷图像存在缺陷细节模糊和纹理信息丢失的问题,现有方法在处理真实场景下的钢轨表面缺陷图像效果不理想,恢复后的图像过于平滑;且当前去模糊方法在侧重于增强图像局部细节的过程中,往往注重于高频信息的提取,缺乏提取图像中低频信息的能力。为此,本文设计了一种由去模糊子网络和超分辨率细节恢复子网络组成的双 CNNs 网络,在增强细节恢复能力的同时提高全局信息的表征能力。其中,去模糊子网络采用基于 U-Net 结构学习模糊图像的语义信息和结构信息,超分辨率细节恢复子网络则用于提高图像清晰度和恢复图像细节特征。此外,为了弥补多次特征提取过程中带来的频率信息损失,在融合模块中的残差块上集成了一个快速傅里叶变换通道,从而更有效地捕获图像中的高低频信息,实现钢轨表面缺陷图像去模糊。

本文的双 CNNs 图像去模糊网络由 5 个不同模块和 2 个子网络组成:

残差模块(residual block, ResBlock):如图 2(a)所示,由两个卷积层和激活函数组成,卷积层之间采用跳跃连接。

双通道残差模块(residual block with FFT, RB-FFT):如图 2(b)所示,在传统残差模块基础上加入了由傅里叶变换、轻量级 1×1 卷积、ReLU 激活函数和傅里叶逆变换组成的快速傅里叶变换(fast Fourier transform, FFT)通道,旨在利用空间域和频率域信息来增强图像去模糊性能。

编码模块(encoder block, Eblock):由激活函数与 3 个 ResBlock 模块相连接,并通过卷积层负责图像的特征提取。

解码模块(decoder block, Dblock):通过激活函数串行连接 3 个 ResBlock 模块和 1 个反卷积层。

去模糊子网络:由 Eblock 模块 E1、E2、E3 和 Dblock 模块 D1、D2、D3 组成的基于 U-Net 结构来完成基本的去模糊任务。




图 2 残差模块与双通道残差模块结构

Fig. 2 Residual block and residual block with FFT structure

超分辨率细节恢复子网络:使用 6 个 ResBlocks 提取高维特征以实现图像的超分辨率,以及 2 个 Eblock 模块与 2 个 ResBlock 模块相串联用于图像细节恢复和保留。

融合模块:通过 2 个 Eblock 模块将去模糊子网络和超分辨率细节恢复子网络提取的特征进行融合,再通过两个 RB-FFT 模块输出最终去模糊图像。

双 CNN 图像去模糊网络结构参数如表 1 所示。

表 1 网络参数

Table 1 Network parameters

Block	Channel	Layer	Kernel Size	Stride
E1	64	Conv	5×5	1
	64	ResBlock	5×5	1
	64	RB-FFT	5×5	1
	128	Conv	5×5	2
	128	ResBlock	5×5	1
	128	RB-FFT	5×5	1
E2	256	Conv	5×5	2
	256	ResBlock	5×5	1
	256	RB-FFT	5×5	1
	256	Deconv	4×4	2
	256	ResBlock	5×5	1
	256	RB-FFT	5×5	1
E3	256	Conv	5×5	2
	256	ResBlock	5×5	1
	256	RB-FFT	5×5	1
	256	Deconv	4×4	2
	256	ResBlock	5×5	1
	256	RB-FFT	5×5	1
D1	256	Conv	5×5	1
	256	ResBlock	5×5	1
	256	RB-FFT	5×5	1
	128	Deconv	4×4	2
	128	ResBlock	5×5	1
	128	RB-FFT	5×5	1
D2	64	Conv	4×4	1
	64	ResBlock	5×5	1
	64	RB-FFT	5×5	1
	64	Deconv	4×4	1
	64	ResBlock	5×5	1
	64	RB-FFT	5×5	1
D3	64	Conv	4×4	1
	64	ResBlock	5×5	1
	64	RB-FFT	5×5	1
	128	Conv	5×5	1
	128	ResBlock	5×5	1
	32	Conv	5×5	1
融合模块	32	Conv	5×5	1
	32	RB-FFT	5×5	1
	32	RB-FFT	5×5	1

1.4 损失函数

本文结合了曝光控制损失函数、 L_2 损失函数和频率损失函数来集成到端到端训练网络中,其中曝光控制损失用于调整图像亮度, L_2 损失用于恢复图像的细节和轮廓信息,频率重建损失则用来衡量和优化图像在频域中的全局特性,三者共同优化网络模型,混合损失函数可以表示为:

$$L = L_{ec} + \lambda_1 L_2 + \lambda_2 L_F \quad (9)$$

式中: L_{ec} 为曝光控制损失函数, L_F 为频率重建损失函数, λ_1 和 λ_2 表示取值为 0.1 的权重系数。

曝光控制损失:通过测量反射率局部区域的平均亮度 R_n 与良好曝光度 E 之间的差异,以约束光照不均产生的反射率,曝光控制损失 L_{ec} 可以表示为:

$$L_{ec} = \| \mathbf{R}_n - \mathbf{E} \|^2_2 \quad (10)$$

式中: \mathbf{R}_n 表示对生成的反射率进行 $n \times n$ 平均池化的结果, \mathbf{E} 表示与 \mathbf{R}_n 大小相同且均为 0.7 的矩阵, 在实验中设置 $n = 15$, 以保持亮度和细节的平衡。

L_2 损失函数:

$$L_2 = \frac{1}{N} \sum_{i=1}^N \| f(x_i; \theta) - y_i \|^2 \quad (11)$$

式中: N 表示用于训练模糊与清晰图像对的个数。 $f(x_i; \theta)$ 表示第 i 个训练图像的网络输出, x_i 为训练数据集中的模糊图像, θ 为网络的权值参数, y_i 为相应的清晰图像。

频率重建损失: 用于评估重建图像和原始图像在频域内的差异, 目的是保证重建图像在频域上的特性尽可能接近原始图像, 而不是仅仅在时域上相似, 有助于在保持细节的同时减少高频噪声和失真的影响。频率重建损失定义如下:

$$L_F(X, Y) = \| F(X) - F(Y) \| \quad (12)$$

式中: F 表示傅里叶变换操作, X 为真实的模糊图像, Y 是合成的模糊图像。

2 实验结果与分析

2.1 实验环境

为了验证本文方法的有效性, 本文首先建立了用于训练与测试的数据集和评估指标, 然后定量和定性地评估所提出的方法, 并将其与最先进的方法进行了比较, 最后, 对提出的方法进行消融实验的研究。实验训练环境配置具体如表 2 所示。

表 2 实验训练环境

Table 2 Experimental training environment

编程语言	Python
编辑器	PyCharm
深度学习框架	PyTorch
CPU	i7-7800X
显卡	NVIDIA GeForce RTX 2080-8G
操作系统	64 位 Windows8 系统

2.2 数据集及评价标准

本文采用自制的钢轨表面缺陷模糊图像数据集进行实验, 原始数据集一共 545 张, 包含凹陷、裂纹和掉块 3 种表面缺陷, 采用翻转变换、随机剪裁、亮度变换和镜像等数据增强方法将其扩充至 3 500 张, 每张图像的分辨率为 175×725 。选取了 1 225 对清晰图像与模糊图像作为训练数据集, 其中, 清晰图像是由工业相机固定于小车车架上, 在不同场景下拍摄得到, 模糊图像则是通过鄢化彪等^[14]提出的映射空间方法生成得到, 剩下的 525 对模糊图像和清晰图像作为测试集。采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性指数 (structural similarity, SSIM) 作为两个实验结果的评价指标^[15]。其中, PSNR 通过计算处理后图像与原始图像之间的均方误差 (MSE), 并基于图像像素的最大可能值 (通常为 255, 对于 8 位灰度图像) 来衡量图像质量的变化, PSNR 值越高, 意味着处理后图像与原始图像之间的误差越小, 图像质量越好。PSNR 的计算公式为:

$$PSNR = 20 \lg \left(\frac{MAX}{\sqrt{MSE}} \right) \quad (13)$$

式中: MAX、MSE 分别为图像像素的最大值和均方误差, 计算公式为:

$$MSE = \frac{1}{m \times n} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \| I(i, j) - K(i, j) \|^2 \quad (14)$$

式中: $I(i, j)$ 是原始图像在 (i, j) 位置的像素值, $K(i, j)$ 是处理后图像在相同位置的像素值, m 和 n 分别是图像的行数和列数。SSIM 则用于衡量两幅图像相似度的指标, 通过对比原始图像与处理后图像在亮度、对比度和结构等方面相似程度, 来评估算法对图像质量的提升效果, SSIM 的取值范围在 $[-1, 1]$ 之间, 值越接近 1, 表示处理后图像与原始图像的结构相似性越高。

另外, 还采用了公开的 RSDDs^[16] 钢轨数据集进行图像增强实验, 该数据集包括 195 张钢轨表面缺陷图像, 采用图像的信息熵和对比度进行定量分析。其中, 信息熵用于衡量图像中信息丰富程度, 信息熵越大, 表示图像中蕴含越多信息, 其公式定义为:

$$H = - \sum_{i=1}^{255} p_i \lg p_i \quad (15)$$

式中: i 为像素灰度级别, p_i 是像素值为 i 的像素所占比例。

对比度指图像中不同区域或像素之间灰度差异程度, 对比度越高, 其亮部和暗部之间的差异越明显, 图像中的物体边缘更加清晰, 细节更容易被分辨, 定义如下:

$$C = \left\{ \frac{1}{m \times n} \sum_{i=0}^m \sum_{j=0}^n [I(i, j) - \mu]^2 \right\}^{\frac{1}{2}} \quad (16)$$

式中: m 和 n 分别为图像的行数和列数, $I(i, j)$ 为图像中 (i, j) 的灰度值, μ 为图像的灰度均值。

2.3 实验过程及训练参数

本文采用的网络模型所有卷积核都是 5×5 , 训练时将提取到的钢轨表面区域成对图像裁剪成 80×110 的大小作为网络模型的输入。在网络训练过程中, 迭代训练的最大次数为 1 000 次, 学习率设置为 $1 \times 10^{-4} \sim 1 \times 10^{-6}$, 批大小设为 16, 参数初始化方式为 Xavier。并且使用余弦退火算法和 Adam 优化算法训练本文的网络。另外, 为了避免过拟合, 在模糊图像中加入了高斯随机噪声 (从高斯分布中随机采取不同标准差 $N(0, (2/255)^2)$)。

2.4 实验结果与分析

1) 钢轨表面缺陷图像增强及去模糊评估

为了验证本文算法的有效性, 将本文的方法与目前采

用联合图像增强与去模糊或去噪的深度学习方法进行对比实验,其中包括 MAP^[17] (maximum a posteriori) → Zero-DCE^[18] (Zero-reference deep curve estimation)、MIMO^[19] (multi-input multi-output) → Zero-DCE、Zero-DCE → MIMO 和 RUAS^[20] (retinex-inspired unrolling with architecture search) → MIMO 等提出低光增强与去模糊相级联的方法,以及考虑去噪的低光增强方法,如 Xu 等^[21]提出一种结合信噪比 (signal-to-noise-ratio, SNR) 感知的 Transformer 卷积模型、Li 等^[22]设计一种用于低光照增强的编码器和用于去噪的解码器网络 (low-light enhancement and denoising network, LDNet),还有先进的联合图像增强和去模糊方法,如 Zhou 等^[23]设计的联合低光增强和去模糊网络 (low-light enhancement and deblurring network, LEDNet)、Zhang 等^[24]设计用于图像超分辨率的门控融合网络 (gated fusion network, GFN) 和 Ye 等^[25]提出一种结合高频和边缘信息结构先验网络 (structural priors network, SPNet),此外,还引入了改进前 Retinex 与双 CNNs 相结合的方法。

上述方法均使用本文自制钢轨表面缺陷模糊图像数据集进行训练,且采用相同的测试图像进行性能测试。各方法在自制钢轨表面缺陷模糊图像数据集上的定量测试结果如表 3 所示,可以看出,与串行连接两个网络 (低光增强网络和去模糊网络) 相比,单独训练整个模型可以获得更好的性能。在实验过程中,本文的方法通过自适应地利用不同频率信息学习去模糊特征,以及在边缘纹理信息的有效引导下,该模型在图像增强及去模糊方面表现最好。在性能方面上,相比于改进前的方法,PSNR 和 SSIM 分别提高了 5.31 dB 和 0.093,与最新 SPNet 方法相比,PSNR 和 SSIM 分别比提高了 2.61 dB 和 0.026。另外,从不同网络在处理 80×110×1 单副图像的训练参数和运行时间中可以看出,

LDNet 在训练参数和运行时间上最少,但在性能方面上不能很好满足实际需求。相比之下,本文方法在保持竞争性处理时间的同时,实现了钢轨表面缺陷图像的高质量增强。

不同方法的图像处理效果如图 3 所示,可以看出,使用网络级联的方法得到的结果存在曝光不足或曝光过度的现象,去模糊效果不太理想。经 SNR 处理后的图像亮度略有提升,但整体图像仍然偏暗,图像的细节表现不够清晰。LDNet 处理后的图像缺陷不够清晰,图像质量较为粗糙,降低了整体图像的可视性。LEDNet 和 SPNet 虽然实现了亮度增强和图像去模糊,但不能解决光照不均带来的背景不均匀问题。另外,采用改进前方法得到的图像纹理不清晰,部分图像在暗部区域中产生了噪声。本文改进后的办法处理后的整体图像亮度得到了有效提升,同时背景区域的处理也较为均匀,缺陷边缘更加清晰。

表 3 不同方法在自制钢轨表面缺陷模糊图像数据集上的对比结果

Table 3 Comparison results of different methods on self-made rail surface defect blur image dataset

方法	PSNR/dB	SSIM	Parameters/M	时间/s
MAP → Zero-DCE	15.96	0.326	—	—
MIMO → Zero-DCE	16.33	0.445	—	—
Zero-DCE → MIMO	16.55	0.419	—	—
RUAS → MIMO	16.79	0.462	—	—
SNR	20.24	0.631	39.50	0.10
GFN	22.38	0.725	14.31	0.07
LDNet	25.18	0.796	0.38	0.02
LEDNet	25.57	0.819	8.82	0.15
改进前方法	23.12	0.758	13.07	0.14
SPNet	25.82	0.825	40.25	0.12
本文方法	28.43	0.851	14.52	0.16




图 3 不同方法在自制钢轨表面缺陷模糊图像数据集上的处理效果

Fig. 3 Processing effect of different methods on self-made rail surface defect blur image dataset

2) 钢轨表面缺陷图像增强评估

为了验证本文所提出的改进 Retinex 图像增强算法的有效性,将其与直方图均衡化(histogram equalization, HE)、MSR 和融合边缘信息的对比度增强算法^[26]进行了实验对比,不同算法对钢轨表面缺陷图像处理后的视觉效果对比如图 4 所示。采用 HE 算法得到的图像出现了过度增强和背景噪声。使用文献[26]算法处理后的图像整体较为模糊,在钢轨表面缺陷边缘没有体现细节信息。而经 MSR 算法处理后的图像在一定程度上增强了缺陷和背景的对比度,但钢轨表面图像存在背景不均匀的现象。相比之下,本文所提出的改进 Retinex 算法实现了较好的增强效果,比改进前 MSR 具有更高的对比度和更突出的缺陷边缘信息,比 HE 具有更少的噪声。

各方法的评价指标如表 4 所示,可以看出,本文算法增强结果的 3 个指标均高于其他方法,与改进前 MSR 相比,每幅图像的平均信息熵和对比度分别提高了 0.45、0.124。在运算时间方面,由于加入了控制图像动态参数,总体运算时间略高于 MSR 算法。




图 4 不同算法的钢轨表面缺陷图像增强效果比较

Fig. 4 Comparison of rail surface defect image enhancement effects of different algorithms

3) 钢轨表面缺陷图像去模糊评估

为了验证本文采用双 CNNs 去模糊算法的有效性,使用自制钢轨表面缺陷模糊图像数据集将其与目前去模糊方法进行对比实验。其中包括基于盲图像和非盲图像去模糊的方法,如 Chen 等^[27]提出一种基于局部最大梯度先验(local maximum gradient, LMG)的盲去模糊的方法、Lanza 等^[28]提出一种基于交替方向乘法(alternating

directions methods of multipliers, ADMM)策略的最小化算法,以及 Zhang 等^[29]提出基于端到端卷积神经网络去模糊的方法(encoder-decoder deblurring and super-resolution network, ED-DSRN),还有基于深度学习的方法,如 Kupyn 等^[30]提出一种端到端生成对抗网络去模糊(deblur generative adversarial network, DeblurGAN-v2)的方法、Kim 等^[31]设计一种多尺度阶段网络(multi-scale-stage network, MSSNet)的方法。

表 4 所有测试图像的平均指标

Table 4 Average metrics for all test images

方法	信息熵	对比度	时间/ms
原图像	7.516	0.179	—
HE 方法	7.832	0.181	27.8
文献[26]方法	7.759	0.186	836
MSR 方法	7.913	0.194	785
本文方法	8.563	0.318	894

各方法的评价数值和去模糊后的效果如表 5 和图 5 所示。采用 LMG 方法得到的图像边缘不清晰,且含有噪声。经 ADMM 处理后的图像出现伪影的现象,导致目标缺陷边缘模糊,降低了整体图像的可视性。经 ED-DSRN 处理后的图像虽然提高了图像清晰度,但在缺陷细节方面不够明显。MSSNet 处理后的图像在保留细节和控制亮度方面有所改善,但图像质量较为粗糙。本文方法处理后得到的图像边缘清晰明了,细节信息更加丰富,图像质量提升显著。从表 5 可以看出,ADMM 所需参数量最少,其他方法由于结合了深度学习,网络参数量也随之增加。相比之下,本文采用双 CNNs 去模糊算法在参数量相差不大的情况下,得到的图像更加清晰,缺陷细节更加明显。在性能方面,相较于 MSSNet,PSNR 和 SSIM 分别提高了 0.18 dB、0.012,与 ED-DSRN 相比,PSNR 和 SSIM 分别提高了 3.81 dB、0.143。

表 5 不同去模糊方法的评价指标对比

Table 5 Comparison of evaluation indicators of different defuzzing methods

对比方法	PSNR/dB	SSIM	Parameters/M	时间/s
ADMM	15.96	0.247	4.53	0.10
LMG	18.69	0.524	13.26	0.15
ED-DSRN	22.34	0.685	12.04	0.16
MIMO-UNet	23.94	0.716	16.21	0.17
MSSNet	25.97	0.816	28.15	0.21
本文方法	26.15	0.828	13.17	0.14

2.5 消融实验

为了验证本文图像增强算法不同模块(自适应非线性




图 5 不同算法的钢轨表面缺陷图像去模糊效果比较

Fig. 5 Comparison of rail surface defect image deblurring effects of different algorithms

增强、改进的 Retinex 和自适应伽马变换)的有效性, 使用 RSDDs 数据集建立了 3 组消融实验, 定性结果如图 6 所示, 定量比较如表 6 所示。从图 6 中可以看出, 与原图像相比, 采用方法 I 得到的图像产生了伪影现象。采用方法 II 进行图像增强时, 增强的结果存在曝光不足的现象。而使用方法 III 输出的图像产生亮度不均、阴影突凸的视觉结果。相比之下, 方法 IV 是本文采用改进的 Retinex 在光照不均中发挥了重要作用, 获得最好的视觉效果。




图 6 消融实验定性结果

Fig. 6 Qualitative results of ablation study

另外, 为了验证本文所采用的去模糊子网络和超分辨率细节恢复子网络的有效性, 设计了两组消融实验, 在保持其他结构不变条件下, 使用自制钢轨表面缺陷模糊图像数据集进行网络训练, 再用训练好的网络模型进行测试。去模糊消融实验效果如图 7 所示, 可以看出, 单独采用去模糊子网络的模型具有良好的去模糊性能, 但在模糊程度

较严重的情况下, 去模糊后的图像细节出现严重丢失。本文所提出的超分辨率细节恢复子网络, 能够有效地恢复和保留图像细节信息。

表 6 消融实验定量比较

Table 6 Quantitative comparison of ablation study

方法	自适应非 线性增强	自适应伽 马变换	改进 Retinex	信息熵	对比度
I			✓	8.106	0.289
II	✓		✓	8.058	0.285
III	✓	✓		7.892	0.191
IV	✓	✓	✓	8.563	0.318




图 7 钢轨表面图像去模糊效果对比

Fig. 7 Contrast diagrams of rail surface image deblurring effect

如表 7 所示, 由带有去模糊子网络和超分辨率细节恢复子网络构建的网络模型比单个去模糊子网络构建的网络模型的 PSNR 和 SSIM 分别提高了 2.51 dB 和 0.037, 比

单个超分辨率细节恢复子网络构建的网络模型的 PSNR 和 SSIM 分别提高了 2.08 dB 和 0.018。

表 7 不同子网络消融实验

Table 7 Different sub-network ablation experiments

去模糊子网络	超分辨率细节恢复子网络	PSNR/dB	SSIM
✓		25.92	0.817
	✓	26.35	0.836
✓	✓	28.43	0.854

3 结论

为解决由于光照不均、镜头抖动等外界因素的影响,导致采集的钢轨表面缺陷图像存在对比度低、背景不均匀和缺陷细节模糊等问题,本文提出了一种基于改进 Retinex 与双 CNNs 的钢轨表面缺陷图像增强算法。首先,利用 HSV 空间中 S 分量对光照不敏感的特点,对其进行自适应非线性增强,克服图像采集过程中光照不均的影响,并对 V 分量通过改进 Retinex 算法和自适应伽马变换,提高缺陷与背景对比度的同时校正图像曝光;其次,采用基于 U-Net 结构的去模糊子网络,通过多尺度输入获取模糊图像上的多尺度信息,提高网络的去模糊能力;最后,设计的超分辨率细节恢复子网络,实现了对语义特征和细节纹理特征的完整提取,获得了更好的图像纹理和更丰富的图像细节信息。实验结果表明,相较于现有的主流算法,本文方法在主观和客观评价上均表现良好,在 PSNR 和 SSIM 分别比第 2 名提高了 2.61 dB 和 0.026。

未来将考虑对网络模型的结构和参数进行调整,在保证较好的增强效果的同时减少训练时间,后续研究将会针对该类问题做进一步改进。

参考文献

- [1] ZDENKA P, LUKA L, MILICA M, et al. Critical analysis of RCF rail defects classification [J]. Transportation Research Procedia, 2022, 63: 2550-2561.
- [2] 姚宗伟, 杨宏飞, 胡际勇, 等. 基于机器视觉和卷积神经网络的轨道表面缺陷检测方法 [J]. 铁道学报, 2021, 43(4): 101-107.
- [3] YAO Z W, YANG H F, HU J Y, et al. Track surface defect detection method based on machine vision and convolutional neural network [J]. Journal of the China Railway Society, 2021, 43(4): 101-107.
- [4] 王伟江, 彭业萍, 曹广忠, 等. 面向机柜表面缺陷检测的不均匀光照和低亮度图像增强方法 [J]. 仪器仪表学报, 2019, 40(8): 131-139.
- [5] WANG W J, PENG Y P, CAO G ZH, et al. Non-uniform and low illumination image enhancement for cabinet surface defect detection [J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 131-139.
- [6] 何磊, 易遵辉, 谢永芳, 等. 基于 Retinex 先验引导的低光照图像快速增强方法 [J]. 自动化学报, 2024, 50(5): 1035-1046.
- [7] HE L, YI Z H, XIE Y F, et al. Fast enhancement method for low light images guided by Retinex prior [J]. Acta Automatica Sinica, 2024, 50(5): 1035-1046.
- [8] 罗晖, 李健, 贾晨. 基于图像增强与改进 Cascade R-CNN 的钢轨表面缺陷检测 [J]. 激光与光电子学进展, 2021, 58(22): 324-335.
- [9] LUO H, LI J, JIA CH. Rail surface defect detection based on image enhancement and improved Cascade R-CNN [J]. Laser & Optoelectronics Progress, 2021, 58(22): 324-335.
- [10] 侯庆璐, 高银, 王茂华, 等. 结构稀疏通道先验盲图像去模糊方法 [J]. 电子测量与仪器学报, 2023, 37(12): 107-116.
- [11] HOU Q L, GAO Y, WANG M H, et al. Blind image deblurring method with structural sparse channel prior [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 107-116.
- [12] 孙妍, 甄国涌, 储成群, 等. 基于二阶梯度的暗通道先验盲图像去模糊 [J]. 电子测量技术, 2023, 46(15): 103-110.
- [13] SUN Y, ZHEN G Y, CHU CH Q, et al. Dark channel a priori blind image deblurring based on second order gradient [J]. Electronic Measurement Technology, 2023, 46(15): 103-110.
- [14] LIM S, KIM J, KIM W. Deep spectral-spatial network for single image deblurring [J]. IEEE Signal Processing Letters, 2020, 27(99): 835-839.
- [15] 孙晶晶, 张艳艳, 高超, 等. 基于 DeblurGAN 的运动模糊图像盲复原算法研究 [J]. 电子测量技术, 2022, 45(22): 112-119.
- [16] SUN J J, ZHANG Y Y, GAO C H, et al. Research on blind restoration algorithm of motion blur image based on DeblurGAN [J]. Electronic Measurement Technology, 2022, 45(22): 112-119.
- [17] LI L Y, ZHU CH Z, CHEN J L, et al. Self-supervised normalizing flow for jointing low-light enhancement and deblurring [J]. Circuits, Systems, and Signal Processing, 2024, 43: 5727-5748.
- [18] ZHANG ZH H, CHENG Y X, SUO J L, et al. INFOWIDE: Image and feature space wiener deconvolution network for non-blind image deblurring in low-light conditions [J]. IEEE Transactions on Image Processing, 2023, 32: 1390-1402.
- [19] XU P, ZENG H M, QIAN T F, et al. Research on defect detection of high-speed rail based on multi-frequency excitation composite electromagnetic

- method[J]. Measurement, 2022, 187(3): 110351.
- [13] ZHU R N, GUO ZH Q, ZHANG X L. Forest 3D reconstruction and individual tree parameter extraction combining close-range photo enhancement and feature matching [J]. Remote Sensing, 2021, 13 (9): 1633-1633.
- [14] 鄢化彪, 刘词波, 黄绿娥, 等. 基于映射空间编码的高速运动轨道图像去模糊研究[J]. 铁道科学与工程学报, 2024, 21(2): 812-825.
- YAN H B, LIU C B, HUANG L E, et al. Research on deblurring of high-speed motion railway images based on mapping spatial coding[J]. Journal of Railway Science and Engineering, 2024, 21(2): 812-825.
- [15] ZHANG K H, REN W Q, LUO W H, et al. Deep image deblurring: A survey[J]. International Journal of Computer Vision, 2022, 130(9): 2103-2130.
- [16] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [J]. ArXiv preprint arXiv: 1612.02177, 2016.
- [17] CHEN L, ZHANG J W, LIN S N, et al. Blind deblurring for saturated images[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2021: 6304-6312.
- [18] GUO CH L, LI CH Y, GUO J CH, et al. Zero-reference deep curve estimation for low-light image enhancement [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 1777-1786.
- [19] CHO S J, JI S W, HONG J P, et al. Rethinking coarse-to fine approach in single image deblurring[C]. 2021 IEEE/CVF International Conference on Computer Vision(ICCV), 2022: 4621-4630.
- [20] LIU R SH, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2021: 10556-10565.
- [21] XU X G, WANG R X, FU C W, et al. SNR-aware low-light image enhancement [C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2022: 17693-17703.
- [22] LI Y H, LIU T Y SH, FAN J X, et al. LDNet: Low-light image enhancement with joint lighting and denoising [J]. Machine Vision and Applications, 2022, 34(1), DOI:10.1007/S00138-022-01365-Z.
- [23] ZHOU SH CH, LI CH Y, LOY C C. LEDNet: Joint low-light enhancement and deblurring in the dark[C]. 2022 ECCV Lecture Notes in Computer Science (LNCS), 2022: 573-589.
- [24] ZHANG X Y, DONG H, HU ZH, et al. Gated fusion network for degraded image super resolution [J]. International Journal of Computer Vision, 2020, 128 (6): 1699-1721.
- [25] YE J, YANG L J, QIU CH ZH, et al. Joint low-light enhancement and deblurring with structural priors guidance [J]. Expert Systems With Applications, 2024, 249: 123722.
- [26] 郭钰璐, 董丽丽, 许文海. 融合边缘信息的对比度增强算法[J]. 红外技术, 2019, 41(7): 616-622.
- GUO Y L, DONG L L, XU W H. A contrast enhancement algorithm incorporating edge information[J]. Infrared Technology, 2019, 41(7): 616-622.
- [27] CHEN L, FANG F M, WANG T T, et al. Blind image deblurring with local maximum gradient prior[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 1742-1750.
- [28] LANZA A, MORIGI S, SGALLARI F. Convex image denoising via non-convex regularization with parameter delection [J]. Journal of Mathematical Imaging and Vision, 2016, 56(2): 195-220.
- [29] ZHANG X, WANG F, DONG H, et al. A deep encoder-decoder networks for joint deblurring and super-resolution [C]. 2018 IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP), 2018: 15-20.
- [30] KUPYN O, MARTYNIUK T, WU J, et al. DeblurGAN-v2: Deblurring (orders-of-magnitude) faster and better[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 8877-8886.
- [31] KIM K, LEE S, CHO S. MSSNet: Multi-scale-stage network for single image deblurring [C]. European Conference on Computer Vision, 2023: 524-539.

作者简介

- 罗晖(通信作者),硕士,教授,主要研究方向为图像处理、机器视觉、人工智能及物联网技术等。
E-mail:2529684115@qq.com
- 章硕士,硕士研究生,主要研究方向为深度学习、图像处理。
E-mail:669960674@qq.com
- 曾伟,博士,副教授,主要研究方向为量子机器学习、人工智能及其应用等。
E-mail:zengweixigua@163.com
- 张金华,硕士研究生,主要研究方向为深度学习、语义分割。
E-mail:2741140190@qq.com