

文章编号 1004-924X(2025)10-1609-18

浮选泡沫低照度图像颜色深度编解码校正及 多尺度增强

孙磊^{1,2}, 唐倩¹, 廖一鹏^{1*}, 廖玉华¹, 董则希¹, 何建军³

(1. 福州大学 物理与信息工程学院, 福建 福州 350108;

2. 福州大学 至诚学院, 福建 福州 350002;

3. 福建金东矿业股份有限公司, 福建 三明 365101)

摘要: 浮选现场环境恶劣、光照条件复杂多变, 针对现场采集的浮选图像易出现曝光不足、颜色失真等问题, 提出了一种低照度图像颜色深度编解码校正及多尺度增强方法。首先, 将低照度图像从 RGB 转换至 HSV 空间, 针对明度(V)分量, 采用非下采样剪切波变换(NSST)进行多尺度分解; 其次, 提出基于全局空间模块的色彩编解码网络, 通过挤压提取、色彩编码、色彩解码、颜色校正构建颜色深度编解码校正网络模型, 对色度(H)、饱和度(S)分量进行颜色校正; 然后, 采用自适应模糊集增强 V 分量的低频子带图像, 利用尺度相关系数有效滤除 V 分量中各高频子带的噪声成分, 同时使用非线性增益函数对高频边缘系数进行显著增强处理; 最后, 对增强后的 V 分量各子带图像作 NSST 反变换重构, 并将重构后的 V 分量与校正后的 H 分量、S 分量融合转换回 RGB 空间。通过实验验证, 与当前的主流方法相比, 本文方法 CIEDE 平均降低 14.835 8, PSNR 平均提高 8.48 dB, 结构相似度平均提高 31.32%, 连续边缘像素比保持在 91% 以上。本文方法显著改善了图像的亮度, 提升了对比度、清晰度和信息熵, 使图像颜色更接近真实色彩, 保留了更多纹理细节, 并在有效抑制噪声的同时, 实现了边缘增强。

关键词: 浮选泡沫; 低照度图像; 颜色校正; 颜色深度编解码网络; 多尺度增强与去噪; 非下采样剪切波变换; 模糊集中图分类号: TP394.1; TH691.9 文献标识码: A

doi: 10.37188/OPE.20253310.1609

CSTR: 32169.14.OPE.20253310.1609

Multi-scale enhancement and color depth codec correction of flotation foam low illumination images

SUN Lei^{1,2}, TANG Qian¹, LIAO Yipeng^{1*}, LIAO Yuhua¹, DONG Zexi¹, HE Jianjun³

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China;

2. School of Zhicheng College, Fuzhou University, Fuzhou 350002, China;

3. Fujian Jindong Mining Co. Ltd., Sanming 365101, China)

* Corresponding author, E-mail: fzu_lyp@163.com

Abstract: The environment of flotation site is harsh, and the lighting conditions are complicated and variable. For the flotation images collected on-site were prone to underexposure, color distortion, and other problems, a low-illumination image color depth coding and decoding correction and multiscale enhancement method was proposed. First, the low-illumination image was converted from RGB to HSV space,

收稿日期: 2024-12-17; 修订日期: 2025-03-04.

基金项目: 国家自然科学基金资助项目 (No. 62271149, No. 62271151); 福建省自然科学基金项目 (No. 2019J01224)

and for the value (V) component, the non-subsampled shearlet transform (NSST) was used to perform multi-scale decomposition. Second, a color depth codec correction network based on the global spatial module was proposed, and the color depth coding and decoding correction network model was constructed through squeeze extraction, color coding, color decoding, and color correction. Color correction was performed for the hue (H) and saturation (S) components. Then, the low-frequency subband images of the V component were enhanced by adaptive fuzzy set, and the noise components of each high-frequency subband image of the V component were effectively filtered out using the scale correlation coefficient, while the high-frequency edge coefficients were significantly enhanced using the nonlinear gain function. Finally, the enhanced images of the various subbands of the V component were reconstructed by the inverse transform of the NSST, and the reconstructed V component was fused with the corrected H and S components and converted back to RGB space. Experimental results demonstrate that, compared with current mainstream methods, the proposed method achieves an average reduction of 14.835 8 in CIEDE, an average increase of 8.48 dB in PSNR, and an average improvement of 31.32% in structural similarity, with the continuous edge pixel ratio maintained above 91%. The proposed method enhances image brightness, achieving higher contrast, clarity, and information entropy. The image colors are closer to true colors, preserving more texture details, and edges are enhanced while effectively suppressing noise.

Key words: flotation foam; low illumination images; color correction; color depth codec correction network; multi-scale enhancement and denoising; non-subsampled shearlet transform; fuzzy sets

1 引 言

泡沫浮选是目前矿物分选中应用最广的技术之一,也是矿物加工领域的重要核心手段。在浮选过程中,泡沫层的表面包含了许多与工艺条件和性能密切相关的关键信息,这些信息可以通过提取泡沫表面特征来分析和优化浮选工艺^[1-2]。尤其是泡沫表面的颜色特征,其直接影响着浮选试剂用量的动态调整以及相关工艺参数的设定。然而,由于浮选过程通常在开放环境下进行,泡沫层的颜色信息易受自然光、室内照明等多种光源的综合影响。即使在同一日内,随着光照强度和入射角度的变化,泡沫图像的颜色信息也可能受到严重干扰。

目前,大部浮选泡沫视觉研究都是在理想光照条件下进行,而忽视了实际现场中光照变化、灰尘干扰和雾气等复杂因素的影响,采集的泡沫图像普遍存在亮度低、对比度不足、噪声干扰、颜色失真以及边缘模糊等问题,严重影响了后续对泡沫颜色和形态提取的准确性与稳定性。浮选泡沫图像常见的颜色校正策略多采用图像颜色风格的跨域转换,Liu等^[3]通过双生成对抗网络(GANs)实现了在泡沫纹理结构保持不变的前提

下对图像颜色的校正;针对浮选泡沫图像常因光照条件不一致而导致颜色偏差及亮点过多的挑战,Wang等^[4]设计了一种基于光照域信号引导的无监督生成对抗网络框架(IDS-GUGAN),旨在实现浮选泡沫图像光照条件的一致性校正,有效解决了图像在光照变化下产生的颜色失真问题。陈宁等^[5]提出了一种基于Contourlet域统计建模的颜色恒常校正方法,用于校正泡沫图像中的颜色偏移问题。王宇龙等^[6]提出一种融合局部直方图均衡化与三维块匹配滤波技术的策略,有效应对了浮选泡沫图像中光照缺失、噪声污染及边缘模糊等问题。肖文辉等^[7]针对浮选泡沫形变和坍塌等特性,提出一种基于气泡稳定性评估的时空联合去噪算法,该算法不仅能有效去除浮选泡沫图像中的噪声,还能恢复泡沫的纹理细节,提升了图像信息的可读性。Xie等^[8]提出一种结合区域分解和引导滤波的方法,在光照不足的区域该方法利用引导滤波器引导像素从相邻的较亮点获取亮度信息,以增强暗部细节;而在其他区域,则通过精细调节像素值的变化幅度,避免了图像过度曝光,从而全面提升了图像的整体质量。廖一鹏等^[9]提出一种结合自适应分数阶微分和非下采样Contourlet变换的多尺度图像增强方

法,显著改善了图像的对比度、细节表现、噪声控制,但忽略了可能出现色偏及轻微过曝光等问题。

近年来,研究人员对低照度图像颜色校正或增强做了一定研究,Ning等^[10]提出了一种基于自适应多尺度Retinex与色彩恢复(MSRCR)算法的低照度图像增强技术,旨在克服传统Retinex算法中需要手动调整参数以及可能导致细节模糊的问题,有效提升了低照度条件下的图像质量。王昊天等^[11]改进了CycleGAN算法,实现了对水下图像颜色的高效校正;Li等^[12]提出了一种结合非下采样轮廓波变换与多尺度Retinex的增强算法,用于改善浮选泡沫图像的低频子带;陈清江等^[13]设计了一种基于多通道融合注意力网络的低照度图像增强算法,显著提升了图像亮度与对比度;季渊等^[14]针对舞台场景拍摄中的动态范围受限问题,提出了一种改进Retinex算法用于低照度增强;吕伏等^[15]提出一种多尺度低照度图像增强算法,通过亮度均衡和边缘强化改善图像表现。这些方法在低照度环境下取得了一定成效,但在提升图像色彩的过程中,往往无法有效保留细微结构;而在关注细节增强时,又可能削弱颜色校正效果。

目前,学术界已涌现出若干颇具成效的低照度图像增强与颜色校正策略:Li等构建一种零参考深度曲线估计网络(Zero-DCE)^[16]通过动态范围估计及像素与高阶曲线的关联,实现了对低照度图像的有效调整;Gharbi等^[17]提出一种基于双边网格处理和局部仿射颜色变换的神经网络结构用于实时图像增强;针对图像中既存在曝光过度又存在曝光不足的照明问题,Wang等^[18]创新性地提出了局部颜色分布嵌入模块,并基于此构建了多尺度的LCDPNet;为了应对弱光环境中的图像增强、曝光校正和色调映射挑战,Yang等^[19]提出了LA-Net,该网络在低频层进行光自适应调整,同时在高频层聚焦于噪声抑制与细节增强;此外,石吉豪等^[20]依据光线散射衰减模型,开发了一种低照度图像增强算法,该算法能够有效抑制噪声并提升图像的亮度与对比度。Shi等^[21]提出一种零样本框架,旨在联合执行低光图像的去噪与增强任务,该方法通过融合反射与照明信息,从原始低光图像中分离出反射成分,进

而实现噪声的有效去除。针对当前图像增强算法普遍存在的颜色失真难题,Chang等^[22]提出一种基于Ghost-Block和独特图像分解策略的低光增强网络,其能够恢复出自然的颜色分布,并达到照明平衡,显著提升图像视觉效果。Brateanu等^[23]提出一种轻量级Transformer模型LYT-Net,该网络通过独立处理色度与亮度信息,增强了模型在照度调整与受损区域恢复方面的能力,为低光条件下的图像质量提升提供了新的解决方案。然而,这些方法普遍面临一个共同的挑战,即在进行颜色校正或细节增强时,往往难以兼顾噪声抑制效果。

针对上述问题,提出一种结合颜色深度编解码校正与多尺度增强策略的低照度图像处理方法。首先,将低照度图像转换至HSV颜色空间,并构建颜色深度编解码校正网络模型对H,S分量进行颜色校正。其次,针对泡沫图像无背景、全前景、泡沫排列紧密等特点,提出一种适用于颜色校正的全局空间模块以更好地捕获图像空间与通道之间的相互关系,有效解决泡沫图像颜色失真问题。随后,对V分量进行NSST多尺度分解,并采用自适应模糊集对分解得到的低频子带分量进行有效增强处理,结合尺度相关系数消除各高频方向子带中的噪声,并利用非线性增益函数增强边缘系数,以减少图像亮度不足、对比度低、细节少及噪声干扰等关键问题。最后,对增强后的V分量各子带图像进行NSST重构,并将重构后V分量与校正后H,S分量融合变换至RGB颜色空间。最后,用公用数据集和自构建的铅、锌矿真实数据集来验证所提出方法的有效性和优越性。

2 算法原理与流程

2.1 颜色空间选取

选取恰当的颜色空间是校正颜色分量的首要步骤,当前广泛采用的颜色空间涵盖了RGB,HIS,LCH,LAB以及HSV等。相较于RGB空间,HSV空间展现出其独特优势,主要体现在H,S,V三个分量彼此独立,互不干扰,且无需依赖于RGB三原色的相互关联。HIS,LCH,LAB以及HSV这些颜色空间均是基于人类视觉系统的特性构建,并具备光照稳定性,适用于多种图像

处理场景。在运算效率方面,HSV 模型相较于 HIS,LCH 和 LAB 空间具备更优的处理速度,能够满足实时性要求较高的应用场景。然而,HIS 空间的亮度分量(I)在转换过程中可能会损失部分信息,从而对颜色的精确度造成一定影响。此外,由于 LCH 和 LAB 空间转换过程具有非线性特征,在跨设备使用时需特别关注色彩一致性的保持,以避免出现色彩偏差。综合上述分析,本文在进行颜色校正与增强任务时,选择了 HSV 颜色空间作为处理基础,以充分利用其分量独立性、处理速度优势及光照稳定性特点。

2.2 算法整体框架与步骤

本文提出的算法框架如图 1 所示,具体步骤如下:

Step1:将低照度图像从 RGB 颜色空间转换到 HSV 颜色空间,并分别处理 H,S 和 V 分量。

Step2:将低照度图像划分为训练集和测试集,并将 H,S 分量输入至本文提出的颜色深度编解码校正网络 (Color Depth Codec Correction Network, CDCC-Net) 进行训练,以获得经过深

度颜色校正的 H,S 分量。

Step3:利用 NSST 对 V 分量进行多尺度分解,得到低频子带 (Low Frequency Subband, LFB) 和高频子带 (High Frequency Subband, HFB),并分别进行如下优化:针对 LFB,采用广义对比度增强算子 (Generalized Contrast Enhancement Operator, GCEO) 增强其模糊因子,并通过量子细菌觅食算法 (Quantum Bacteria Feeding Algorithm, QBFA)^[24]对模糊因子进行优化,以提升亮度的自适应调整能力;针对 HFB,利用非线性增益函数 (Nonlinear Gain Function, NGF) 增强高频子带的弱边缘系数,并通过尺度相关系数 (Scale Correlation Coefficient, SCC) 消除高频子带中的噪声干扰。

Step4:对增强后的 V 分量各子带图像进行 NSST 反变换,以重构出优化后的 V 分量图像。

Step5:将深度颜色校正后的 H,S 分量与增强后的 V 分量相结合,并从 HSV 空间转换回 RGB 空间,从而得到同时具备颜色校正、亮度增强与去噪效果的优化图像。




图 1 算法整体框架图

Fig. 1 Overall framework diagram of the algorithm

2.3 颜色深度编解码校正网络模型

泡沫颜色特征对于矿物浮选过程监测起着至关重要作用,本文构建的颜色深度编解码校正网络

如图 2(a)所示,主要包括四个关键模块,如图 2(b)~2(e)所示,即挤压提取块(SEB),色彩编码块(CEB),色彩解码块(CDB)和颜色校正块(CCB)。




图 2 颜色深度编解码校正网络及其子模块架构

Fig. 2 CDCC-Net and submodules architecture

2.3.1 挤压提取块(SEB)

SE层函数^[25]作为一种注意力机制,集成进卷积神经网络后,能够增强网络对通道间依赖关系的学习能力,从而提升网络对信息特征的敏感性,并有效抑制无关特征的影响。为了解

决通道依赖性问题,在感受野较小的低层网络中,学习过滤器通过局部感受野进行操作,确保每个输出单元只能利用该区域内的信息,而无法获得区域外的上下文。因此,使用全局平均池化生成通道统计数据,将全局空间信息压缩

为通道描述符,如图 2(b)所示。其中,输入特征表示为 f^i ,处理后的特征 f^o 可以通过以下方法导出:

$$f_1^i = C_{1 \times 1}\{GAP(f^i)\}, \quad (1)$$

$$f_2^i = C_{1 \times 1}\{Relu(f_1^i)\}, \quad (2)$$

$$\omega_i = \frac{1}{1 + e^{-f_2^i}}, \quad (3)$$

$$f^o = f^i \times \omega_i. \quad (4)$$

在 SE 模块的基础上,首先进行全局平均池化 GAP,改进过程中采用 $C_{1 \times 1}$ 卷积层来取代原 SE 模块中用于通道注意力信息学习的全连接层。首先,对输入的特征图 f^i 进行了全局平均池化,以提取更高层次的特征信息,从而将特征图从 $[h, w, c]$ 矩阵形式转换为 $[1, 1, c]$ 向量形式,将此向量确定的内核大小应用于一维卷积运算得到 f_1^i 。然后,使用 $Relu$ 激活函数将特征值 f_1^i 限制在非负范围内减少模型参数的数量,并再次输入到一维卷积运算得到 f_2^i 。随后使用 Sigmoid 函数对这些通道权重进行标准化,得到 ω_i 。最后,将归一化权重 f^i 与原始输入特征图通道乘以 ω_i ,生成加权特征图 f^o 。该模块通过调整卷积核大小来优化感受野,从而更好地捕获全局信息中的局部特征,进一步增强了模型在图像色彩校正方面的性能。

2.3.2 色彩编码块(CEB)

如何对 SEB 处理后的特征信息进行编码是一个关键性问题,本文受 LFENet^[26] 启发,在 CDCC-Net 中设计了四层 CEB 模块,逐步进行下采样编码,如图 2(c)所示。该模块采用带有残差结构的网络模型用于特征提取,通过三个阶段分别专注给每一个特征分配唯一的权重以及挖掘空间依赖性和通道间的信息。最终,经过前两阶段处理的特征输入至 GSM 模块,以进一步精确提取空间信息。通常提高模型准确性的传统方法是增加网络的深度或宽度,但这种做法会导致参数量增加,进而提升计算成本和模型复杂度。SIM 注意力机制^[27] 提供了一种无需增加参数复杂度即可提升精度的方案,同时能够减少超参数的数量。首先,在第一阶段对输入特征进行 LN 标准化,通过 SIM 注意力机制和 SimpleGate 机制^[28] 与 $C_{5 \times 5}$ 卷积获取到一个特征权重,该机制有

助于最小化激活过程中的信息丢失,更有效地捕获空间中的相关性。随后,将获得的权重与原始图像相加,得到包含注意力信息的特征矩阵。其中, LN 表示标准化, Att_{sim} 表示 SIM 注意力机制, SG 表示 SimpleGate 机制,第一阶段处理后的特征 f_1^o 可以通过以下方法导出:

$$f_1^{i1} = C_{5 \times 5}\{Att_{sim}(LN(f^i))\}, \quad (5)$$

$$f_1^{i2} = C_{1 \times 1}\{SG(f_1^{i1})\}, \quad (6)$$

$$f_1^o = f^i + f_1^{i2}. \quad (7)$$

第二阶段将该特征矩阵再次通过与第一阶段类似的操作。其中, SE 表示 SE 函数,第二阶段的输入特征为第一阶段的输出特征,第二阶段处理后的特征 f_2^o 可以通过以下方法导出:

$$f_2^{i1} = C_{5 \times 5}\{SE(LN(f_1^o))\}, \quad (8)$$

$$f_2^{i2} = C_{1 \times 1}\{SG(f_2^{i1})\}, \quad (9)$$

$$f_2^o = f_1^o + f_2^{i2}. \quad (10)$$

第三阶段,本文提出全局空间模块(Global Spatial Module, GSM),该模块由 Global Attention Module (GAM) 和 Spatial Attention Module (SAM) 堆叠而成,使之具有更好地细化空间特征信息的能力,强调图像中不同位置的重要性,该模块及其子模块如图 3 所示,子模块 GAM 被设计为一种降低信息损失并增强全局交互特性的策略。首先采用两层多层感知器(MLP)来放大跨维度通道的空间依赖性,然后使用两个 $C_{7 \times 7}$ 卷积层来处理空间信息融合,最后使用两个阶段的 Sigmoid 函数对这些通道权重进行标准化。




图 3 GSM 及其子模块架构

Fig. 3 GSM and submodules architecture

在对输入特征图进行处理时, SAM 会沿着通道维度分别执行最大池化和平均池化操作,这两种池化方式能够捕捉并生成具有不同上下文尺度的特征。具体来说,最大池化能够强化显著

特征,而平均池化则提供了更加全面的上下文信息。随后,SAM将最大池化和平均池化后的特征在通道维度上进行连接。这一步骤旨在融合两种池化方式所捕获的不同尺度信息,从而生成一个包含丰富上下文信息的特征图。接下来利用 $C_{7 \times 7}$ 卷积层处理这个特征图,以生成空间注意力权重再通过 Sigmoid 函数将权重限制在 $[0, 1]$ 。最后,将计算出的空间注意力权重用于原始特征图,并对各个空间位置的特征进行了加权

处理。这样可以突出重要的图像区域,并减少不重要的区域的影响。将经过前两阶段的输出特征输入到 GSM 得到最终输出,具体过程如下:

$$GAM = \text{Sigmoid} \{ C_{7 \times 7} (C_{7 \times 7} (\text{Sigmoid} (MLP(x_i)))) \}, \quad (11)$$

$$SAM = \text{Sigmoid} \left\{ C_{7 \times 7} \left(P_{\text{Avg}} \left(P_{\text{Max}}(y_i) \right) \right) \right\}, \quad (12)$$

$$GSM = x_i \times GAM(x_i) \times SAM(y_i), \quad (13)$$

其中: x_i 表示输入特征, y_i 表示输入特征 x_i 与经过 GAM 的输入特征相乘,即 $y_i = x_i \times GAM(x_i)$, MLP 表示两层多层感知器, P_{Avg} 表示平均池化, P_{Max} 表示最大池化。该模块能对图像信息进行颜色编码,并通过通道与空间注意力对特征进行细化处理,减少冗余信息的同时提高模型的鲁棒性。

在颜色解码部分,本文采用三层 CDB 进行三层上采样,如图 2(d)所示。与 CEB 模块不同, CDB 模块在最后阶段减少了 GSM 模块的处理,这是因为在编码阶段的特征提取需要更加精确,并强调有用信息的提取,而在解码阶段,这种精细的处理并非关键。

2.3.3 颜色校正块(CCB)

在颜色校正阶段,输入特征经过编码块后将分为 5 个支路进行下一步的处理,其中一路即经过下采样后输入到下一个编码块,而其余的四路则是输入到 CCB 中,如图 2(e)所示,首先将编码后的输入特征 f^i 经过 $C_{3 \times 3}$ 卷积获取到一个特征权重,再与原输入特征逐元素相乘得到 f_1^i 。然后将此特征权重 f_1^i 分别经过 Softmax 激活函数与 ReLU 激活函数,ReLU 函数优化了梯度消失的问题,并显著提升了收敛速度,调整网络参数以最

小化损失,与 f_1^i 逐元素相乘得到 f_2^i 。最后将 f_2^i 与原输入特征向量 f^i 逐元素相加通过 $C_{1 \times 1}$ 卷积得到最后输出。计算公式如下:

$$f_1^i = f^i \times C_{3 \times 3}(f^i), \quad (14)$$

$$f_2^i = f_1^i \times \text{Relu}(\text{Softmax}(f_1^i)), \quad (15)$$

$$f_o = C_{1 \times 1}(f^i + f_2^i). \quad (16)$$

2.4 NSST 域 V 分量低照度增强及去噪

为了解决低照度增强过程中噪声放大、纹理细节流失等问题,本文对低照度泡沫图像的 V 分量进行 NSST 多尺度分解为高低频域分别进行增强与去噪,其流程如图 4 所示。采用自适应模糊集方法增强低频子带,在高频方向子带结合尺度相关系数去除噪声,同时通过非线性增益函数增强边缘系数,综合应对图像亮度、对比度不足、细节模糊以及噪声干扰等问题。




图 4 V 分量多尺度增强与去噪流程

Fig. 4 Multiscale enhancement and denoising process of V

2.4.1 低频子带自适应模糊集增强

模糊集增强方法在模糊特性域处理图像中的像素^[29],将一幅具有 L 个灰度级的 $M \times N$ 元图像作为图像的模糊特征平面。首先,将图像数据从直观的空间域转换到更为复杂的模糊域表示:

$$Z = \bigcup_{m=1}^M \bigcup_{n=1}^N \frac{G_{mn}}{Z_{mn}}, \quad (17)$$

其中: Z 表示整个图像的模糊域,由所有像素点的模糊特征组成; Z_{mn} 表示图像中位置 (m, n) 处的像素值; G_{mn} 为像素 Z_{mn} 的模糊隶属度函数值,如式 (18)所示:

$$G_{mn} = D(Z_{mn}) = \left[1 + \frac{Z_{\max} - Z_{\min}}{Y_f} \right]^{-Y_e}, \quad (18)$$

其中: $m \in [1, M]$, $n \in [1, N]$; 参数 Y_f 表示指数型模糊因子, 控制模糊变换的尺度; Y_e 表示倒数型模糊因子, 控制模糊度的衰减速率; $D(\cdot)$ 表示模糊变换函数。然后, 采用了广义对比度的增强算子:

$$V'_{mn} = \begin{cases} 2^{i-1}(V_{mn})^i, & 0 \leq V_{mn} \leq 0.5 \\ 1 - 2^{i-1}(1 - V_{mn})^i, & 0.5 < V_{mn} \leq 1 \end{cases} \quad (19)$$

最后, 进行模糊集反变换 D^{-1} :

$$Z'_{mn} = D^{-1}(V'_{mn}) = Z_{\max} - Y_f[(V'_{mn})^{-1/Y_e} - 1]. \quad (20)$$

在模糊集增强算法中, 参数 Y_f 和 Y_e 对增强效果具有重要影响。随着乘幂值 i 的增大, 增强后图像的对比度也随之提高, 但过大的 i 值可能导致图像失真。为了优化 Y_f , Y_e 和参数 i , 本文采用改进的量子细菌觅食算法进行寻优, 其适应度函数为:

$$L = B \times \lg(C \times Q), \quad (21)$$

其中: L 表示适应度函数, B 为图像信息熵, C 为图像对比度, Q 为图像清晰度。

2.4.2 结合尺度相关系数的边缘系数增强及去噪

为降低噪声对后续处理干扰, 在边缘增强前先剔除噪声系数。本文结合高频域的能量特征, 计算出合适的阈值和尺度相关系数。设子带在位置 (p, q) 的系数为 R_s^j , 子带系数的平均值为 $\bar{R}_s^j$, 在第 s 尺度方向上, 子带的总数量是 J , 而在第 s 尺度的第 j 方向上的子带系数能量表示为 E_s^j , 计算噪声阈值 TH_s^j :

$$TH_s^j = \frac{\sum_{j=1}^J E_s^j}{2JE_s^j} \sqrt{\frac{1}{P \times Q} \sum_{p=1}^P \sum_{q=1}^Q [R_s^j(p, q) - \bar{R}_s^j]^2}. \quad (22)$$

$$I_s^j = \begin{cases} 0, & R_s^j(p, q) < 0.8TH_s^j \\ 0, & 0.8TH_s^j \leq R_s^j(p, q) \leq 1.2TH_s^j \text{ and } C_s^j(p, q) < R_s^j(p, q) \\ \max(R_s^j) k\left(\frac{R_s^j(p, q)}{\max(R_s^j)}\right), & 0.8TH_s^j \leq R_s^j(p, q) \leq 1.2TH_s^j \text{ and } C_s^j(p, q) \geq R_s^j(p, q) \\ \max(R_s^j) k\left(\frac{R_s^j(p, q)}{\max(R_s^j)}\right), & R_s^j(p, q) > 1.2TH_s^j \end{cases} \quad (25)$$

若简单地将低于阈值的系数去除, 可能会导致部分弱边缘系数被错误地识别为噪声而被剔除, 反之则有可能将噪声误认为弱边缘系数而增强。根据边缘系数与噪声系数在 NSST 多尺度域分别展现出强相关和弱相关的特征, 本文为进一步区分并去除弱相关的噪声系数, 同时增强强相关的边缘系数, 定义 $\prod_{s=1}^S R_s^j(p, q)$ 为位置 (p, q) 处不同尺度系数相乘后的结果, $E\left(\prod_{s=1}^S R_s^j(p, q)\right)$ 代表第 s 尺度、第 j 方向子带 $\prod_{s=1}^S R_s^j(p, q)$ 中系数的能量值。基于此, 定义 (p, q) 在第 s 尺度第 j 方向子带上的尺度相关系数 $C_s^j(p, q)$ 为:

$$C_s^j(p, q) = \prod_{s=1}^S R_s^j(p, q) \sqrt{\frac{E_s^j}{E\left(\prod_{s=1}^S R_s^j(p, q)\right)}}. \quad (23)$$

在调整边缘系数时, 依据特定的增强函数进行修正大于 $0.8TH_s^j$ 的系数, 其中, a 作为控制强度的参数, 此处设定为 20; 而 b 表示增强的范围, 其值位于 $[0, 1]$ 的区间内。 x 为函数自变量; $W(x) = 1/(1 + e^{-x})$ 。为了更精确地描述增强过程引入子带的最大系数 $\max(R_s^j)$, 并基于这些参数定义增强函数如下:

$$k(x) = \frac{W(a(x-b)) - W(-a(x+b))}{W(a(1-b)) - W(-a(1+b))}. \quad (24)$$

假设增强处理的系数为 $I_s^j(p, q)$, 处理方法如式(25)所示, 直接剔除小于阈值 $0.8TH_s^j$ 的噪声系数, 增强大于阈值 $1.2TH_s^j$ 的边缘系数。当系数位于 $[0.8TH_s^j, 1.2TH_s^j]$ 范围内时结合尺度间的相关系数, 一方面增强弱边缘系数, 另一方面去除噪声系数。

3 实验结果与分析

3.1 实验环境与数据集

本文实验环境:软件平台为 Ubuntu 20.04 操作系统、Python3.8, PyTorch1.8.1 和 Matlab 2023a, 硬件平台为具有 24 GB 内存的 Nvidia RTX 3090 GPU。在训练阶段模型使用 AdamW 优化器进行优化,学习率为 2×10^{-4} 。批量大小设置为 4,训练 200 个 epoch。

铅-锌浮选泡沫数据集 (Lead-Zinc Flotation Foam Dataset, LZFF):在福建金东矿业有限公司的梅仙选矿厂采集了铅-锌浮选泡沫图像,均在正常的工业浮选生产条件下,于白天正常光照和夜晚低光照环境下获取,详细记录了铅、锌浮选回路中粗选、扫选和精选状态下的泡沫图像,80% 的 4 725 张图像用作训练数据,剩余 20% 的 1 181 张图像作为测试数据。铅精选泡沫数据集 (Lead Refined Flotation Foam Dataset, LRFF):与 LZFF 数据集的采集过程相同,LRFF 数据集是对铅的进一步精选过程,该过程是对粗选得到的产物进行进一步的提纯,以提高铅矿的品位。精选过程结束后,得到的精选槽泡沫经过浓密、烘干等后续处理,最终成为浮选过程的选矿产

品。LRFF 数据集中 80% 的 2 880 张图像用作训练数据,剩余 20% 的 720 张图像作为测试数据。

Low-Light 数据集:为了验证提出模型及方法的泛化性能,本文额外选用来自北京大学 Wei 等^[30]从真实场景中获取的用于低光增强的图像对的数据集,包含 500 个低光/正常光图像对,尺寸为 400×600 大小,这个数据集包含各种类型的自然图像,旨在检验所提出的模型对于与矿物浮选不直接相关的图像数据的处理能力。

为了全面且准确地量化评估各方法在低照度泡沫图像处理中的性能,引入了信息熵、对比度、清晰度、纹理相关性、峰值信噪比 (PSNR) 以及连续边缘像素比 (EPI) 作为核心评估指标。

3.2 低照度增强效果及对比分析

三种不同工况泡沫图像的低照度增强效果及比较如图 5 所示,各项指标统计如表 1 所示。文献[13]方法在提升泡沫图像的信息熵、对比度和清晰度方面取得了一定成效,但该方法在放大图像细节的同时,也显著放大了噪声,增强后图像存在大量噪声点,导致 PSNR 值较低,整体提升效果有限。文献[14]所提出的方法在对比度、清晰度及信息熵方面均实现了显著提升,但这一过程中同样伴随着噪声的放大,气泡内部的大量




图 5 各方法在三种不同工况泡沫数据集上的增强效果

Fig. 5 Enhancement effect of each method on three different working condition foam dataset

表 1 各方法在三种不同工况泡沫数据集上的增强比较

Tab. 1 Comparison of the enhancement of each method on three different working condition foam datasets

Method	Comentropy	Contrast	Resolution	Texture correlation/%	PSNR/dB
Low illumination foam image	6.397 0	22.300 8	12.114 0	20.93	24.043 1
Method in Ref. [13]	7.200 7	22.453 3	15.758 5	7.82	14.582 2
Method in Ref. [14]	6.682 7	50.603 8	19.868 1	12.87	15.011 4
Method in Ref. [15]	6.508 4	30.750 9	16.368 4	9.30	24.706 1
Method in Ref. [9]	7.540 5	59.052 4	24.614 3	23.13	25.867 0
Proposed method	7.683 1	61.431 6	25.677 8	24.71	26.391 7

纹理细节在增强过程中丢失,导致纹理相关性指标下降。文献[15]中的算法在对比度、清晰度及信息熵上都有一定提升,PSNR值也相对较高,但该方法由于采用单一的噪声阈值处理策略,导致部分噪声被误判为边缘而过度放大,同时部分弱边缘则被当作噪声进行平滑处理,引发了散斑现象和边缘失真。相比之下,文献[9]方法在对比度、清晰度及信息熵的提升上表现较佳,且较好地保留了图像的纹理细节,PSNR值也相对较高,表明其在抑制噪声方面取得了一定的成效,但该方法的亮度和对比度有待进一步提升。本文所提方法不仅显著改善了图像的亮度,还保持了较高的对比度、清晰度和信息熵水平,在有效抑制噪声的同时,更好地保留了图像中的纹理细节。从数据上看,本文方法的纹理相关性提高了3.7%,PSNR值提高了1.82 dB,表明本文方法在提升图像质量的同时,还实现了更好的噪声抑制和纹理细节保留效果。

3.3 颜色校正效果及对比分析

为对颜色校正性能进行客观评价与对比,采用CIEDE^[31]作为衡量颜色校正效果的评价指标。

铅锌矿浮选泡沫数据集实验及比较:表2详细对比了在LZFF数据集上应用不同方法的颜色校正效果,本文方法的PSNR,SSIM和CIEDE分别达到了24.090 dB,0.841和1.007,这三项指标均显著优于所有参与比较的方法。图6直观地展示了不同方法在该数据集上的增强视觉效果。LA-Net与GDNet虽然在细节修复方面有一定的优势,但增强后的图像在色彩方面存在一定的偏差;LCDPNet,ZeroIG以及MSRCR在处理过程中均出现了较为明显的颜色失真现象,影响了图像的视觉质量;RUAS因为过曝光的问题,

表 2 各方法在铅锌浮选泡沫数据集上的性能比较

Tab. 2 Comparison of the performance of the methods on LZFF dataset

Method	PSNR/dB ↑	SSIM ↑	CIEDE ↓
Zero-DCE ^[16]	16.841	0.510	24.440
HDRNet ^[17]	9.910	0.594	21.338
LCDPNet ^[18]	10.995	0.304	21.211
LA-Net ^[19]	20.727	0.599	6.728
RUAS ^[20]	19.577	0.632	5.497
MSRCR ^[10]	10.861	0.278	21.387
ZeroIG ^[21]	9.318	0.153	35.890
GDNet ^[22]	15.246	0.789	18.686
LYT-Net ^[23]	20.813	0.750	11.720
Proposed method	24.090	0.841	1.007

导致许多重要的图像细节丢失;而Zero-DCE和HDRNet虽然在一般光照条件下表现出色,但在面对极端黑暗环境下采集到的图像时,其增强效果并不理想;LYTNet在亮度提升方面表现出优越性能,但在处理泡沫等复杂纹理时,边缘出现伪影,导致细节纹理的丢失问题较为严重;相比之下,本文方法则展现出了卓越的颜色校正能力,能够显著提升图像的色彩还原度和整体视觉效果。

铅精选泡沫数据集实验及比较:表3对比了在LRFF数据集上应用不同方法的颜色校正效果,本文方法的PSNR,SSIM和CIEDE分别达到了28.461 dB,0.905和2.502,这三项指标均显著优于其他参与比较的方法。图7直观地展示了不同方法在该数据集上的增强视觉效果。在亮度增强方面,Zero-DCE,HDRNet和LCDPNet适当提升了亮度,但仍然偏暗,细节未完全恢复;LA-Net和RUAS提升亮度较明显,但部分区域




图 6 各方法在铅锌浮选泡沫数据集上的增强效果

Fig. 6 Enhancement effect of each method on LZFF dataset

出现了过曝现象,尤其是RUAS的亮度过度增强,导致对比度失衡;本文方法在亮度提升上表现均衡,既提升了亮度又保持了图像的自然感,没有出现明显的过曝或欠曝问题。在细节恢复方面,Zero-DCE和HDRNet在暗部区域的细节恢复不够充分,许多关键信息仍然隐藏在阴影之中,难以辨识;MSRCR,ZeroIG,GDNet和LYTNet在增强亮度的同时,提升了一定的细节信息,但MSRCR,ZeroIG,GDNet出现了色彩失

真问题,影响了图像的真实性;LYTNet在泡沫边缘等复杂纹理处出现了伪影;本文方法在增强细节的同时,仍能较好地保持原始纹理信息,避免了伪影的产生。在色彩校正方面,Zero-DCE,HDRNet和LCDPNet存在颜色偏差问题,导致图像整体偏暗;RUAS在颜色上过度增强,使得图像的自然感降低;本文方法颜色还原较为准确,没有出现明显的色偏和过饱和问题,保持了图像的自然色彩和真实感。




图 7 各方法在铅精选泡沫数据集上的增强效果

Fig. 7 Enhancement effect of each method on LRFF dataset

表 3 各方法在铅精选泡沫数据集上的性能比较

Tab. 3 Comparison of the performance of the methods on LRFF dataset

Method	PSNR/dB ↑	SSIM ↑	CIEDE ↓
Zero-DCE ^[16]	6.876	0.290	83.815
HDRNet ^[17]	7.956	0.390	72.202
LCDPNet ^[18]	5.859	0.181	91.877
LA-Net ^[19]	27.348	0.872	3.734
RUAS ^[20]	9.212	0.372	62.047
MSRCR ^[10]	9.930	0.451	51.305
ZeroIG ^[21]	8.660	0.365	68.310
GDNet ^[22]	21.729	0.830	5.965
LYT-Net ^[23]	24.922	0.835	5.283
Proposed method	28.461	0.905	2.502

Low-Light数据集实验及比较:在 Low-Light数据集上使用不同算法的增强效果如图 8 所示,客观指标统计如表 4 所示,本文所提方法,其峰值信噪比(PSNR)性能指标达到了 21.657 dB,结构相似性指数(SSIM)达到了 0.872,CIEDE 指标达到了 10.088。在亮度提升方面,Zero-DCE 和

HDRNet 仍然保留了一定的暗部信息,增强幅度不足,导致部分细节难以辨认;LCDPNet 亮度提升上表现较为显著,但出现了严重的色偏问题,影响视觉体验。RUAS 和 LA-Net 在亮度增强上较为显著,PSNR 达到了 23.387 dB;但 RUAS 过度增强导致了局部过曝;本文方法亮度提升较为自然,与 Ground Truth 相比,没有出现明显的欠曝或过曝现象,增强效果较为均衡。在细节方面,Zero-DCE 和 HDRNet 由于增强幅度较小,暗部仍然存在细节丢失的问题;LCDPNet 由于色彩失真,细节恢复效果较差;MSRCR 和 ZeroIG 在细节恢复方面表现较好,但 ZeroIG 在部分区域层次感较低;本文方法在细节保留方面表现更佳,能够在提升亮度的同时保留丰富的纹理信息。在色彩校正方面,LCDPNet 颜色失真严重,不符合真实场景;RUAS 虽然提升了亮度,但出现了颜色失真的问题;GDNet 和 LYTNet 在色彩还原方面表现较好,能够较为准确地还原图像中的颜色信息;本文方法在色彩还原方面优于大多数比较方法,能够在保持颜色真实感的同时,有效地




图 8 各方法在 Low-Light 数据集上的增强效果

Fig. 8 Enhancement effect of each method on Low-Light dataset

表 4 各方法在 Low-Light 数据集上的性能比较

Tab. 4 Comparison of the performance of the methods on the Low-Light dataset

Method	PSNR/dB $\uparrow$	SSIM $\uparrow$	CIEDE $\downarrow$
Zero-DCE ^[16]	9.406	0.353	43.697
HDRNet ^[17]	14.734	0.622	45.445
LCDPNet ^[18]	10.239	0.357	53.697
LA-Net ^[19]	23.387	0.869	15.375
RUAS ^[20]	13.067	0.680	14.826
MSRCR ^[10]	14.210	0.523	18.681
ZeroIG ^[21]	18.835	0.712	13.147
GDNet ^[22]	23.746	0.784	17.131
LYT-Net ^[22]	16.545	0.799	14.804
Proposed method	21.657	0.872	10.088

提升整体亮度、恢复和保留细节信息以及准确地还原颜色信息。

3.4 边缘增强及抗噪声性能比较

铅锌浮选泡沫数据集实验及比较:分别对图像叠加方差为 10%, 20%, 30% 的噪声进行实验, 几种方法的图像增强和边缘检测效果如图 9 所示, PSNR 和 EPI 的统计结果如表 5 所示。

RUAS 检测边缘附近存在大量噪点且明暗细节丢失,效果不佳。LANet 对于低照度图像的抗噪声能力较差,且在亮度提升方面需要进一步加强。HDRNet 方法检测到的边缘存在断裂现象,且边缘附近有大量噪点。文献[14]和文献[20]方法相较其他对比算法的 PSNR 值和 EPI 值较高,增强后检测到的边缘虽然较为完整,但是过滤掉了许多边缘细节信息,色偏较为严重。文献[9]方法除本文方法外指标均高于其他方法,抗噪能力较强,边缘清晰且完整,但该方法增强后的图像存在色偏现象。在噪声方差 10% 的情况下,本文方法得到的 PSNR 平均提升了 6.21 dB,而 EPI 平均提升了 21.86%;当噪声方差达到 20% 时,PSNR 的平均增幅为 7.48 dB,而 EPI 的平均增幅为 25.33%;当噪声方差达到 30% 时,PSNR 的平均增幅为 8.02 dB,而 EPI 平均提升了 29.42%。本文方法指标均为最佳,有较优的抗噪声和边缘增强能力,从视觉效果上看所提方法不仅能够有效地改善亮度和对比度,而且色彩、纹理还原效果较好;细节增强方面也优于其他算法,增强光照不佳的浮选图像鲁棒性强。




图 9 各方法对铅锌矿浮选泡沫数据集的去噪和边缘检测效果

Fig. 9 Denoising and edge detection effectiveness of each method on LZFF dataset

表 5 各方法在 Low-Light 数据集上的去噪和边缘检测性能统计

Tab. 5 Denoising and edge detection performance statistics of each method on Low-Light dataset

Noise variance	Index	RUAS	LA-Net	HDRNet	Method in Ref. [20]	Method in Ref. [14]	Method in Ref. [9]	Proposed method
10%	PSNR/dB	14.191 1	22.608 8	12.455 2	22.812 7	22.903 9	23.271 3	23.874 8
	EPI/%	0.551 9	0.662 7	0.569 3	0.332 3	0.189 5	0.647 2	0.690 9
20%	PSNR/dB	14.186 0	22.520 1	12.291 7	22.780 2	21.903 3	22.294 3	22.684 1
	EPI/%	0.547 8	0.664 6	0.568 1	0.337 4	0.194 1	0.635 8	0.675 7
30%	PSNR/dB	14.130 0	22.333 5	11.275 1	21.782 6	20.909 4	21.392 6	21.524 2
	EPI/%	0.543 0	0.660 8	0.556 1	0.520 2	0.588 1	0.661 8	0.663 5

Low-Light 数据集实验及比较:为了进一步客观验证所提方法的抗噪声性能和边缘增强效果,对低照度图像叠加了均值为 0,10%,20%,30% 方差的高斯噪声进行增强实验,如图 10 第一到三行所示。利用 Laplacian 算子检测增强后的低照度图像中的边缘信息,采用峰值信噪比 PSNR 评估降噪性能,以连续边缘像素比 EPI 来衡量边缘增强效果,EPI 值越高说明图像的边缘连续性越好,边缘增强效果相应也越好。将所提方法与现有文献方法进行对比分析,增强及边缘检测效果如图 10 所示,PSNR 和 EPI 的统计结果如表 6 所示。本文方法在噪声方差为 10% 的情况下,增强后的噪声图像的 PSNR 值为 23.8748 dB,EPI 值为 0.690 9。文献[9]方法相较其他对比算法的 PSNR 值和 EPI 值较高,但从图 8 的视觉效果可以看出该方法的降噪效果

不佳,图像中仍残留一定噪点;尽管增强后的边缘检测较为完整,但图像过饱和,影响视觉效果。文献[14]方法的增强效果和去噪效果较好,但亮度较低。RUAS 由于曝光过度导致检测到的边缘明显,但存在许多噪点,去噪性能不佳。LA-Net 和 HDRNet 方法检测到的边缘较为完整,但存在色彩偏差、模糊效应等问题,且边缘附近有大量噪点。文献[20]方法增强后的图像出现了过曝光现象,但该方法的去噪效果相较于其他方法表现出卓越性能。本文方法在噪声方差为 30% 的情况下,PSNR 值欠佳于 LA-Net 方法,但 PSNR 依然保持在 21.524 2 dB,EPI 保持在 66.35%,且有较优的抗噪声能力,检测到的边缘较为清晰、完整、噪点较少,在添加噪声方差为 10% 和 20% 的情况下指标较其他方法均为最优。




图 10 各方法对 Low-Light 数据集的去噪和边缘检测效果

Fig. 10 Denoising and edge detection effectiveness of each method on Low-Light dataset

表 6 各方法在铅锌矿浮选泡沫数据集上的去噪和边缘检测性能统计

Tab. 6 Denoising and edge detection performance statistics of each method on LZFF dataset

Noise variance	Index	RUAS	LA-Net	HDRNet	Method in Ref. [20]	Method in Ref. [14]	Method in Ref. [9]	Proposed method
10%	PSNR/dB	14.191 1	22.608 8	12.455 2	22.812 7	22.903 9	23.271 3	23.874 8
	EPI/%	0.551 9	0.662 7	0.569 3	0.332 3	0.189 5	0.647 2	0.690 9
20%	PSNR/dB	14.186 0	22.520 1	12.291 7	22.780 2	21.903 3	22.294 3	22.684 1
	EPI/%	0.547 8	0.664 6	0.568 1	0.337 4	0.194 1	0.635 8	0.675 7
30%	PSNR/dB	14.130 0	22.333 5	11.275 1	21.782 6	20.909 4	21.392 6	21.524 2
	EPI/%	0.543 0	0.660 8	0.556 1	0.520 2	0.588 1	0.661 8	0.663 5

3.5 消融研究

结构和模块:本文进行了消融研究来分析 CDCC-Net 中每个模块的有效性和贡献。在 LZFF 数据集上进行消融研究,结果如表 7 所示,在网络的编码器部分添加 GSM 块或 SimA 块能提升颜色校正性能。与基线网络相比,同时包含 GSM 块和 SimA 块的网络在 PSNR 和 SSIM 方面均有改进:PSNR 从 22.438 dB 提升至 24.090 dB,增幅达 1.652;SSIM 从 0.815 提升至 0.841,增幅为 2.6%;CIEDE 从 3.572 降低至 2.313,降幅达 1.259。结果表明,CDCC-Net 中的 GSM 模块和 SimA 模块对图像色彩校正和增强任务有益,能有效学习全局和局部语义特征,尤其在浮选图像上效果显著,验证了本文方法的有效性。

表 7 铅锌浮选泡沫数据集上 CDCC-Net 各模块的消融研究

Tab. 7 Ablation study of CDCC-Net modules on LZFF dataset

Backbone	GSM	SimA	PSNR/dB ↑	SSIM ↑	CIEDE ↓
✓			22.438	0.815	3.572
✓	✓		23.696	0.835	3.719
✓		✓	22.604	0.825	3.644
✓	✓	✓	24.090	0.841	2.313

颜色空间:以 LZFF 数据集为例对 LAB, LCH, HIS 和 HSV 四种颜色空间进行消融实验,结果如表 8 所示,视觉效果如图 11 所示。使用本

文方法的图像恢复质量排名如下:HSV, HIS, LCH 和 LAB。比较表 8 可得最好的是 HSV 颜色空间,其存在显著的性能增强。在 LAB 空间在增强后的图像在某些区域过于均匀,导致部分细节缺失,局部对比度较弱;LCH 空间对噪声较为敏感,增强后放大了低照度区域的噪声;HIS 空间对比度提升明显,但在泡沫崩塌区域产生过度对比,影响自然度;HSV 空间的色彩稳定性好,增强后颜色信息较为自然,最接近真实值,适用于浮选实时任务。

表 8 铅锌浮选泡沫数据集上颜色空间的消融研究

Tab. 8 Ablation study of color space on LZFF dataset

Color Space	CDCC-Net	Proseed method of V	PSNR/dB ↑	SSIM ↑
LAB	✓		22.209	0.717
		✓	21.552	0.805
	✓	✓	22.397	0.829
LCH	✓		21.274	0.824
		✓	21.519	0.784
	✓	✓	22.681	0.837
HIS	✓		23.853	0.826
		✓	23.044	0.845
	✓	✓	24.916	0.893
HSV	✓		24.090	0.841
		✓	23.281	0.857
	✓	✓	29.062	0.930




图 11 铅锌浮选泡沫数据集上各颜色空间的视觉效果

Fig. 11 Visual effect of each color space on LZFF dataset

4 结 论

针对浮选现场环境恶劣、光照条件复杂多变等因素,采集到的图像易出现曝光不足、颜色失真等问题,提出了低照度图像颜色深度编解码校正及多尺度增强方法。将RGB转换为HSV颜色空间,构建颜色深度编解码校正网络,对H,S分量进行颜色校正,对V分量在NSST多尺度域进行低照度增强和去噪处理,以综合解决浮选泡沫图像颜色失衡、细节模糊、噪声干扰等问题。针对泡沫图像无背景、全前景、泡沫排列紧密等特点,本文设计并验证了一种适用于颜色校正的全局空间模块,该模块能够更有效地捕获图像空间与通道之间的相互关系,实验结果表明,该方法显著改善了泡沫图像的颜色失真问题。对V分量进行了NSST多尺度分解,并采用自适应模糊集来增强低频子带信息,在各高频方向子带上结合尺度相关系数有效去除噪声,同时利用非线性增益函数有效增强边缘系数。通过该方法,可同时提升图像亮度和对比度,增强细节信息,并有效抑制噪声干扰。实验结果表明,与当前的主流方法相比,本文方法CIEDE平均降低14.8358,

PSNR平均提高8.48 dB,SSIM平均提高31.32%,连续边缘像素比保持在91%以上。该方法可以综合提升浮选泡沫图像的信噪比、细节清晰度和色彩稳定性,使得重构图像保留了更丰富的纹理细节,在有效抑制噪声的同时,增强了图像边缘的清晰度和连贯性。与当前主流的低照度图像增强方法相比,所提方法颜色校正结果更接近真实色彩,并在抗噪性能和边缘增强能力上表现更优,为后续浮选泡沫图像特征提取和工况识别等任务奠定基础。

作者贡献声明:

孙磊:研究方法的提出、论文构思、实验结果分析;

唐倩:模型构建与训练、实验设计与测试、初稿撰写;

廖一鹏:算法设计、模型构思、结果验证、论文修改和审核;

廖玉华:数据集构建、实验数据整理;

董则希:实验结果的可视化编程;

何建军:现场数据采集环境搭建、原始数据整理与分类。

参考文献:

- [1] ALDRICH C, AVELAR E, LIU X. Recent advances in flotation froth image analysis[J]. *Minerals Engineering*, 2022, 188: 107823.
- [2] 廖一鹏,陈诗媛,杨洁洁,等. NSST域改进ORB


的泡沫流动特征提取及加药状态识别[J]. *光学精密工程*, 2020, 28(12): 2684-2699.

LIAO Y P, CHEN S Y, YANG J J, *et al.* Dosing status identification and froth flow feature extraction based on improved ORB in NSST domain[J]. *Opt.*

- Precision Eng.*, 2020, 28 (12): 2684-2699. (in Chinese)
- [3] LIU J P, HE J Z, XIE Y F, *et al.* Illumination-invariant flotation froth color measuring *via* Wasserstein distance-based CycleGAN with structure-preserving constraint[J]. *IEEE Transactions on Cybernetics*, 2021, 51(2): 839-852.
- [4] WANG X L, ZHANG Y N, KONG L S, *et al.* Illumination consistency processing based on illumination domain signal-guided unsupervised generative adversarial network for flotation froth images [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 74: 5004916.
- [5] 陈宁, 黄璐, 桂卫华, 等. 泡沫图像统计建模与恒常颜色校正算法研究[J]. *控制理论与应用*, 2016, 33(5): 613-620.
- CHEN N, HUANG L, GUI W H, *et al.* The statistical modeling and constant color correction algorithms for froth image[J]. *Control Theory & Applications*, 2016, 33(5): 613-620. (in Chinese)
- [6] 王宇龙, 王然风, 付翔, 等. 联合 CLAHE 和 BM3D 的浮选泡沫图像预处理方法[J]. *煤炭技术*, 2022, 41(6): 222-224.
- WANG Y L, WANG R F, FU X, *et al.* Image pretreatment of flotation froth based on CLAHE and BM3D fusion[J]. *Coal Technology*, 2022, 41(6): 222-224. (in Chinese)
- [7] 肖文辉, 唐朝晖, 刘金平, 等. 基于气泡稳定性分析的锌浮选泡沫图像时空联合去噪[J]. *控制理论与应用*, 2020, 37(4): 721-730.
- XIAO W H, TANG Z H, LIU J P, *et al.* Stability characteristics-based zinc-flotation froth image denoising fusing spatial-temporal information[J]. *Control Theory & Applications*, 2020, 37 (4): 721-730. (in Chinese)
- [8] XIE Y F, ZHANG B, XIE S W, *et al.* Flotation froth image enhancement based on region decomposition and guided filtering[J]. *Minerals Engineering*, 2024, 216: 108919.
- [9] 廖一鹏, 王卫星, 付华栋, 等. 结合分数阶微分的浮选泡沫图像 NSCT 多尺度增强[J]. *华南理工大学学报(自然科学版)*, 2018, 46(3): 92-102.
- LIAO Y P, WANG W X, FU H D, *et al.* Flotation foam image NSCT multi-scale enhancement with fractional differential[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2018, 46(3): 92-102. (in Chinese)
- [10] NING X, SU J, KOCHAN O. Low-illumination image enhancement method based on adaptive MS-RCR algorithm[C]. *COLINS(I)*, 2023: 93-102.
- [11] 王昊天, 刘庆省, 陈亮, 等. 改进的 CycleGAN 网络用于水下显微图像颜色校正[J]. *光学精密工程*, 2022, 30(12): 1499-1508.
- WANG H T, LIU Q S, CHEN L, *et al.* Improved CycleGAN network for underwater microscopic image color correction [J]. *Opt. Precision Eng.*, 2022, 30(12): 1499-1508. (in Chinese)
- [12] LI J Q, YANG C H, ZHU H Q, *et al.* Improved image enhancement method for flotation froth image based on parameter extraction [J]. *Journal of Central South University*, 2013, 20 (6): 1602-1609.
- [13] 陈清江, 顾媛. 多通道融合注意力网络的低照度图像增强[J]. *光学精密工程*, 2023, 31(14): 2111-2122.
- CHEN Q J, GU Y. Low-light image enhancement algorithm based on multi-channel fusion attention network[J]. *Opt. Precision Eng.*, 2023, 31(14): 2111-2122. (in Chinese)
- [14] 季渊, 李星仪, 马新德, 等. 面向舞台场景的改进 Retinex 低照度图像增强[J]. *光学精密工程*, 2023, 31(17): 2573-2583.
- JI Y, LI X Y, MA X D, *et al.* Improved Retinex low-light image enhancement for stage scenes [J]. *Opt. Precision Eng.*, 2023, 31(17): 2573-2583. (in Chinese)
- [15] 吕伏, 崔向燕, 刘铁. 亮度均衡与边缘强化的多尺度低照度图像增强算法[J]. *激光与光电子学进展*, 2024, 61(12): 451-459.
- LÜ F, CUI X Y, LIU T. Multiscale low-light image enhancement algorithm with brightness equalization and edge enhancement algorithm[J]. *Laser & Optoelectronics Progress*, 2024, 61(12): 451-459. (in Chinese)
- [16] LI C Y, GUO C L, LOY C C. Learning to enhance low-light image *via* zero-reference deep curve estimation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44 (8): 4225-4238.
- [17] GHARBI M, CHEN J W, BARRON J T, *et al.* Deep bilateral learning for real-time image enhancement[J]. *ACM Transactions on Graphics*, 2017, 36(4): 1-12.
- [18] WANG H Y, XU K, LAU R W H. Local Color Distributions Prior for Image Enhancement [M]. *Computer Vision - ECCV 2022*. Cham: Springer Nature Switzerland, 2022: 343-359.
- [19] YANG K F, CHENG C, ZHAO S X, *et al.*

- Learning to adapt to light[J]. *International Journal of Computer Vision*, 2023, 131(4): 1022-1041.
- [20] 石吉豪, 钟羽中, 郑秀娟, 等. 基于光线散射衰减模型的低照度图像增强[J]. *光学精密工程*, 2023, 31(8): 1244-1255.
- SHI J H, ZHONG Y Z, ZHENG X J, *et al.* Low-light image enhancement algorithm based on light scattering attenuation model [J]. *Opt. Precision Eng.*, 2023, 31(8): 1244-1255. (in Chinese)
- [21] SHI Y Q, LIU D, ZHANG L G, *et al.* ZERO-IG: Zero-Shot Illumination-Guided Joint Denoising and Adaptive Enhancement for Low-Light Images [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 3015-3024.
- [22] CHANG R, LIU G, QIAN Y, *et al.* GDNet: a low-light image enhancement network based on Ghost-Block and unique image decomposition[J]. *The Journal of Supercomputing*, 2024, 81(1): 160.
- [23] BRATEANU A, BALMEZ R, AVRAM A, *et al.* Lyt-net: Lightweight yuv transformer-based network for low-light image enhancement [J]. *IEEE Signal Processing Letters*, 2025, 32(3): 2065 - 2069.
- [24] 廖一鹏, 张进, 王志刚, 等. 结合双模多尺度 CNN 特征及自适应深度 KELM 的浮选工况识别[J]. *光学精密工程*, 2020, 28(8): 1785-1798.
- LIAO Y P, ZHANG J, WANG Z G, *et al.* Flotation performance recognition based on dual-modality multiscale CNN features and adaptive deep learning KELM [J]. *Opt. Precision Eng.*, 2020, 28(8): 1785-1798. (in Chinese)
- [25] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 7132-7141.
- [26] ZHAO M H, QIN X D, DU S L, *et al.* Low-light stereo image enhancement and de-noising in the low-frequency information enhanced image space [J]. *Expert Systems with Applications*, 2025, 265: 125803.
- [27] YANG L, ZHANG R Y, LI L, *et al.* Simam: A Simple, Parameter-Free Attention Module for Convolutional Neural Networks [C]. *International Conference on Machine Learning*. PMLR, 2021: 11863-11874.
- [28] CHEN L Y, CHU X J, ZHANG X Y, *et al.* Simple Baselines for Image Restoration [M]. *Computer Vision - ECCV 2022*. Cham: Springer Nature Switzerland, 2022: 17-33.
- [29] 李海军, 孔繁程, 魏嘉或, 等. 基于直觉模糊集和 CLAHE 红外舰船图像增强算法[J]. *兵器装备工程学报*, 2022, 43(11): 88-94.
- LI H J, KONG F C, WEI J Y, *et al.* Based on intuitionistic fuzzy set and CLAHE infrared ship image enhancement algorithm [J]. *Journal of Ordnance Equipment Engineering*, 2022, 43(11): 88-94. (in Chinese)
- [30] WEI C, WANG W, YANG W, *et al.* Deep Retinex Decomposition for Low-Light Enhancement [J]. *ArXiv*, 2018, 1808.04560.
- [31] 刘浩学, 黄敏, 武兵, 等. 彩色数字图像色差计算方法的研究[J]. *光学学报*, 2012, 32(9): 331-340.
- LIU H X, HUANG M, WU B, *et al.* Study of color difference evaluation in color digital images [J]. *Acta Optica Sinica*, 2012, 32(9): 331-340. (in Chinese)

作者简介:



孙磊(1980—),女,福建福州人,博士,教授,硕士生导师。主要研究方向为图像处理与机器视觉、信息光电技术。E-mail: fannysun@163.com

通讯作者:



廖一鹏(1982—),男,福建泉州人,博士,副教授,硕士生导师。主要研究方向为图像处理与分析,工业视觉检测与机器学习。E-mail: fzu_lyp@163.com