

中图法分类号: TP18; TP391 文献标识码: A 文章编号: 1006-8961(2026)05-1300-24

论文引用格式: Xiao F, Duan S, Wang Y L, Ma J X, Cao J C, Liu Y T and Dong J Y. 2026. Survey of underwater image quality assessment research. Journal of Image and Graphics, 31(5):1300-1323(肖帆, 段帅, 王亚领, 马家绪, 曹景超, 刘玉涛, 董军宇. 2026. 水下图像质量评价研究综述. 中国图象图形学报, 31(5):1300-1323)[DOI:10.11834/jig.250516]

水下图像质量评价研究综述

肖帆, 段帅, 王亚领, 马家绪, 曹景超*, 刘玉涛, 董军宇

中国海洋大学信息科学与工程学部, 青岛 266000

摘要: 水体对光的选择性吸收与多重散射以及悬浮颗粒的复杂作用,使水下图像普遍存在色偏、对比度下降、雾化、细节模糊和噪声等复合退化,严重制约了其在海洋探测、生态监测、水下作业机器人等场景中的应用效果。水下图像质量评价(underwater image quality assessment, UIQA)作为连接水下成像机理、图像增强算法与下游视觉任务的关键环节,对于客观衡量图像可用性、指导增强方法优化以及保障任务可靠性具有基础性意义。本文围绕UIQA领域的发展脉络开展系统综述:首先从水下光学成像模型出发,分析不同退化类型的物理成因及其感知表现;其次梳理现有主观质量评价指标及其统计特性,总结主流数据库在规模、标注方式与应用定位上的差异;在此基础上,对传统特征建模方法、深度学习方法、物理模型融合方法以及面向任务的效用驱动评价框架进行分类评述,重点讨论排序学习、多维质量建模、注意力与状态空间模型等新型技术在UIQA中的应用进展。最后,从跨域泛化、主观一致性、可解释性以及“人类感知—机器任务”统一评价等角度分析当前挑战,并对面向真实海洋环境的质量评价体系发展趋势进行展望。本文提及的算法、数据集和评估指标已汇总至<https://www.scidb.cn/s/eum6zf>和<https://github.com/OUC-AI/UIQA>。

关键词: 水下视觉;水下图像质量评价(UIQA);数据库;评价方法;深度学习

Survey of underwater image quality assessment research

Xiao Fan, Duan Shuai, Wang Yaling, Ma Jiaxu, Cao Jingchao*, Liu Yutao, Dong Junyu

Faculty of Information Science and Engineering, Ocean University of China, Qingdao 266000, China

Abstract: Underwater imaging has become a crucial sensing modality for marine science, environmental monitoring, offshore engineering inspection, underwater archaeology, and autonomous robotic operations. However, light propagation in water differs from air propagation due to wavelength-dependent absorption, multiple scattering, and the presence of suspended particles and dissolved matter. Collectively, these factors lead to characteristic degradations including severe color casts, contrast attenuation, veiling light, texture blurring, non-uniform illumination, and signal-dependent noise, thereby limiting visual interpretability and the reliability of subsequent computer vision tasks. Therefore, underwater image quality assessment (UIQA) has emerged as a key research topic, providing quantitative measures of image usability, guiding the optimization of enhancement and restoration algorithms, and serving as an intermediate layer that connects imaging physics, perceptual characteristics, and application-oriented visual systems. Unlike general image quality assessment, UIQA must explicitly consider the physical imaging process in water and the strong coupling between degradation mechanisms and perceptual appearance. Additionally, this assessment must address the multidimensional nature of quality in underwater scenarios, where images that appear visually natural to human observers do not necessarily benefit from machine vision

收稿日期:2025-11-03;修回日期:2026-01-28;预印本日期:2026-02-03

*通信作者:曹景超 caojingchao@ouc.edu.cn

基金项目:山东省自然科学基金项目(ZR2023QF145, ZR2022QF006, ZR2024MF116)

Supported by: Natural Science Foundation of Shandong Province, China(ZR2023QF145, ZR2022QF006, ZR2024MF116)

algorithms, and vice versa. This divergence has driven the field beyond traditional perceptual-consistency modeling toward highly comprehensive frameworks that incorporate physical interpretability and task relevance. This survey presents a systematic review of UIQA from physical, perceptual, and task-oriented perspectives. First, the physical foundations of underwater optical imaging are reexamined, including radiative transfer-based formulations such as the Jaffe–McGlamery model and its simplified variants, and an analysis is provided of how direct transmission attenuation and backscattered light jointly determine the formation of recorded image. Based on this framework, typical degradation categories—such as color shift induced by differential spectral absorption, contrast reduction and haze-like veiling caused by scattering, and texture loss related to forward scattering and motion blur—are discussed in terms of their physical causes and perceptual manifestations. This discussion forms the basis for subsequent quality modeling. Commonly used statistical criteria for evaluating UIQA algorithms, including rank-based correlation measures (SRCC, KRCC), linear correlation (PLCC), and error-based indicators such as RMSE, are then summarized, and their roles in characterizing prediction monotonicity, accuracy, and consistency with subjective ratings are clarified. A detailed review of existing UIQA-related databases is provided, highlighting differences in scale, scene diversity, annotation protocols (absolute scoring versus pairwise ranking), and intended usage (assessment of raw underwater images versus evaluation of enhancement results). Particular attention is also given to recent large-scale datasets with ranking-based and multidimensional annotations, which efficiently capture complex perceptual preferences and support data-driven modeling. From a methodological perspective, existing approaches are categorized into several paradigms: 1) traditional feature-driven methods rely on hand-crafted descriptors derived from color statistics, contrast measures, sharpness indicators, and imaging priors, with representative metrics such as UCIQE, UIQM, and CCF offering clear interpretability and low computational cost but limited capability in modeling nonlinear distortions and algorithm-induced artifacts. 2) Deep learning-based methods learn end-to-end mappings from images to quality scores using convolutional networks, attention mechanisms, Transformer architectures, and, more recently, state space-based models. These methods enable the joint capture of local textures and global context, achieving improved prediction performance and enhanced cross-dataset generalization. 3) Physics-guided deep models incorporate estimated transmission maps, backscatter components, or degradation embeddings into neural architectures to enhance interpretability and align prediction with imaging mechanisms. 4) Task-driven quality assessment redefines image quality in terms of its utility for downstream tasks such as detection and segmentation, using task performance indicators as supervisory signals and revealing systematic discrepancies between human perceptual quality and machine-oriented effectiveness. On this basis, several open challenges are discussed: the high cost and limited scale of reliable subjective annotations; domain shifts across water types, depths, and imaging conditions; the tradeoff between model complexity and interpretability; and the absence of widely accepted frameworks that jointly consider human perception and machine task requirements. Future directions are expected to include multidomain dataset construction, highly efficient annotation strategies, physics-informed representation learning, and adaptive evaluation mechanisms that dynamically adjust quality criteria according to specific application scenario. Therefore, a closed loop can be formed among quality assessment, enhancement, and task performance to support reliable underwater visual perception in real-world marine environments. The methods, datasets, and evaluation metrics mentioned are linked at <https://www.scidb.cn/s/eum6zf> and <https://github.com/OUC-AI/UIQA>.

Key words: underwater vision; underwater image quality assessment (UIQA); database; evaluation method; deep learning

0 引言

水下视觉在海洋科学考察、生态监测、工程检修、智慧渔业与水下机器人自主作业等场景中具有基础性地位(郭继昌等, 2017a)。在专用的水下图像质量评价方法提出之前, 研究人员常沿用自然图

像的评价标准(鄢杰斌等, 2022; 方玉明等, 2021)。然而, 后续研究一致表明, 自然图像的质量评价方法并不适用于评估水下图像的特殊质量退化。如图1所示, 水体对不同波长光线的选择性吸收导致红光快速衰减、蓝光穿透力最强(形成色偏), 而多重散射则进一步叠加了悬浮颗粒、溶解有机物和非均匀照明的影响。这些因素共同导致了水下成像中普遍存

在色偏、对比度下降、雾化、浑浊及细节模糊等复合性退化,严重制约了图像的可读性和可用性(陈龙和丁丹丹,2022)。基于 Jaffe-McGlamery (McGlamery, 1980)等经典成像机理的研究强调,此类退化具有显著的介质依赖性、距离相关性与深度相关性,这证明了在图像质量评价和增强环节中引入物理先验的必要性。

在应用层面,低质量水下图像不仅会损害人类

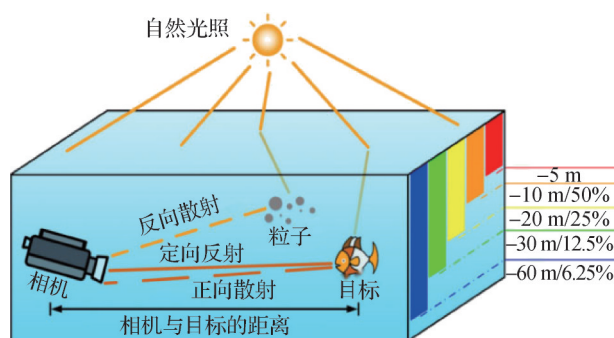


图1 水下成像模型与光衰减示意图

Fig. 1 Underwater imaging model and light attenuation diagram

的主观感知,更直接导致检测、分割和定位等下游计算机视觉任务的精度和鲁棒性严重下降。研究表明,“视觉上更清晰”的增强效果并不必然等同于更高的任务性能,不同数据域和任务目标之间存在显著的偏差。这一脱节现象,凸显了建立一套可解释、可迁移并与任务目标强相关的水下图像质量评价体系的紧迫性。

水下图像质量评价 (underwater image quality assessment, UIQA) 旨在对图像观感与可用度进行可重复的量化,是连接退化机理、水下图像增强 (underwater image enhancement, UIE) 算法 (Jiang 等, 2025a) 以及下游任务的关键枢纽。文中涉及的高频专有名词及其英文全称与中文释义如表 1 所示。

根据周玲等人 (2025b) 的研究,按 UIQA 评估方式的不同,可分为基于传统方法的 UIQA 和基于深度学习的 UIQA。此外,按使用情景可区分为对原始水下图像的质量评价与对增强后图像的质量评价。方法演进方面,早期 UIQA 多以人眼视觉建模与统

表1 高频专有名词缩写表

Table 1 List of frequently used abbreviations

中文全称	英文全称	缩写
水下图像质量评价	underwater image quality assessment	UIQA
水下图像增强	underwater image enhancement	UIE
增强后水下图像质量评价	enhanced underwater image quality assessment	UEIQA
卷积神经网络	convolutional neural network	CNN
人类视觉系统	human visual system	HVS
无参考	no-reference	NR
斯皮尔曼等级相关系数	spearman rank order correlation coefficient	SRCC
肯德尔等级相关系数	Kendall's rank order correlation coefficient	KRCC
皮尔逊线性相关系数	Pearson linear correlation coefficient	PLCC
均方根误差	root mean square error	RMSE
平均意见分	mean opinion score	MOS
真值	ground truth	GT
单刺激	single stimulus	SS
平均精度均值	mean average precision	mAP
交并比	intersection over union	IoU
支持向量回归	support vector regression	SVR
去均值对比度归一化	mean subtracted contrast normalized	MSCN
视觉状态空间模型	visual state space model	VSSM

计特征为核心:UCIQE(underwater color image quality evaluation)(Yang 和 Sowmya, 2015)将色度、饱和度与对比度线性组合以刻画色偏、模糊与低对比度;UIQM(underwater image quality measure)(Panetta 等, 2016)以色彩丰富度、清晰度与对比度加权描述观感质量;CCF(colorfulness, contrast and fog density)(Wang 等, 2018)从成像机理出发,引入颜色、对比度与雾密度等要素以贴合吸收、散射造成的退化。尽管此类方法具有轻量、可解释和易部署的优势,但对非均匀照明、局部色偏与强散射等复杂场景的刻画能力有限,且跨水域、跨设备的稳健性仍需提升。

随着深度学习的发展,UIQA 研究范式由单一分数回归,转向排序学习、多维质量标注与物理先验融合。代表性工作包括:URanker(Guo 等, 2023a)引入直方图先验与跨尺度对应关系,用于判别同场景下不同增强结果的优劣;以主观排序与多维质量标注组织增强结果的 SAUD(subjectively-annotated UIE benchmark dataset)(Jiang 等, 2022)/SAUD2.0(Jiang 等, 2025a),并据此提出的 MCOLE(multi-stream collaborative learning network)(Jiang 等, 2025a)通过颜色、可见度和语义的多流协同学习提升了预测一致性;以及以成像物理为约束的 PIGUIQA(physically imaging guided framework for underwater image quality assessment)(Xian 等, 2025),强化对散射与背向散射的可解释建模。这些进展显著改善了复杂退化与策略多样性下的区分能力。

近年来亦出现面向任务的质量度量趋势:以检测、分割等任务指标或其代理为学习与评价目标,构建效用导向的数据库与预测模型,如 OD-UIUA(object detection-oriented underwater image utility assessment)和 DeepUIUA(deep underwater image utility assessment)(Liu 等, 2025a)。这些实证工作揭示了感知质量与任务效用之间的偏差,并给出了对齐路径。这为闭环系统奠定基础:以任务反馈调节增强策略,并以任务一致的指标指导评价与训练。

综合而言,水下图像质量评价正由“轻量可解释的统计指标”向“深度驱动的排序、多维建模与物理约束融合”演进,并进一步迈向任务一致的效用导向框架。围绕数据库构建与方法设计的协同推进,有望形成“评价—增强—任务”的稳健闭环,有力支撑真实海洋场景下的视觉感知。

尽管目前已有部分文献对水下图像处理领域进

行了综述,但大多聚焦于水下图像增强与复原算法本身(郭继昌 等, 2017a;周玲 等, 2025b),对质量评价方法的讨论往往作为附属章节,缺乏系统性的梳理。与此同时,近3年 UIQA 领域发生了范式转移:1)评价对象细分化。从单一的通用评价分化为“原始水下图像评价”与“增强后水下图像评价”两个截然不同的赛道,两者在特征关注点(如色彩自然度和伪影抑制)上存在显著差异。2)方法架构革新化。以 Transformer、Mamba 及多模态大模型为代表的新一代深度学习架构在 UIQA 中展现出远超传统卷积神经网络(convolutional neural network, CNN)的性能。3)评价目标任务化。评价标准正从单纯的“人眼视觉感知”向“机器视觉效用”拓展。

现有综述难以覆盖上述最新进展。为此,本文旨在填补这一空白,系统梳理从传统特征到最新深度架构的演进脉络,并特别关注排序学习、任务驱动评价等前沿方向。本文主要贡献如下:1)对水下成像模型与常见失真类型进行详细分析,介绍主要失真与感知表现的不同类型,包括颜色偏移、散射影响、纹理细节丢失和人工光源的影响。2)重点对现有 UIQA 数据库和增强数据库的最新进展进行了详细总结。与以往综述仅关注小规模或非公开数据库不同,本文涵盖了 SAUD2.0、UIQD(underwater image quality assessment database)、LSUI(large scale underwater image)等最新的大规模、排序型及多维标注数据库,详细介绍了各个数据库的图像来源、构建方法、局限性与它们面临的开放挑战,为相关的研究者提供研究方向的参考。3)对具有代表性的水下图像质量评价方法进行总结。区别于现有文献笼统的分类,本文明确区分了“原始图像”与“增强图像”的评价范式,系统梳理了包括 Mamba、Transformer 以及多模态融合在内的最新深度学习方法,展现了它们在水下代表性数据库的性能,介绍了两者设计目的与关注重点的差异。4)系统梳理了水下图像质量评价在数据构建、模型解释性、任务适应性与实际部署等方面仍面临的诸多挑战,并提出了对未来研究方向的展望。

1 水下成像模型与常见失真类型

1.1 成像物理模型概述

水下成像物理模型是理解水下图像失真机制的

理论基石,这些模型通常建立在光在水体中的散射和衰减理论之上。其中,Jaffe-McGlamery模型是完备的代表性模型,其简化形式(常借鉴自Koschmieder模型(Koschmieder, 1924))广泛应用于水下图像复原和质量评价中。简化模型将相机接收到的图像分解为直接透射光和背景光两部分,计算式为

$$I(\mathbf{x}) = J(\mathbf{x}) \cdot T(\mathbf{x}) + A \cdot (1 - T(\mathbf{x})) \quad (1)$$

式中, $I(\mathbf{x})$ 为最终拍摄或观测到的水下图像像素值。 $J(\mathbf{x})$ 为理想状况下的场景辐射值(或复原图像),即目标物体在无衰减和散射影响下的真实颜色。该分量携带景物的主要信息,其能量会随传播距离按指数规律衰减,并具有波长依赖性。 A 为背景光,通常指与场景中的目标物体无关,但进入了相机镜头的光线。它在图像成像模型中通常被视为一个均匀的附加项,主要由以下物理过程产生:1)反向散射。这是背景光在水下或雾霾环境中最主要的来源。入射光线(如太阳光)在传播过程中,被介质(水中的粒子或大气中的气溶胶)散射后,直接射向相机镜头。2)物理效果。反向散射光线携带的不是目标物体的清晰信息,而是形成一层均匀的“光幕”或“面纱”,叠加在目标物体反射光之上。3)感知效果。背景光的存在使得图像整体变亮、泛白,严重降低了图像的对比度和色彩饱和度。最后 $T(\mathbf{x})$ 为水体的透射率,表示光线从目标到达相机时未被散射或吸收而保留下来的比例。而 $T(\mathbf{x})$ 的计算又可表示为

$$T(\mathbf{x}) = e^{-\beta \cdot d(\mathbf{x})} \quad (2)$$

式中, $d(\mathbf{x})$ 是目标点 x 到相机的距离(深度)。 β 是衰减系数,表示在水下环境中代表光在水中的综合衰减程度。该模型是许多UIQA方法的重要理论依据,但是在水下,不同颜色光(波长)的衰减系数 β 差异巨大(如红光衰减快、蓝光衰减慢)。模型通常默认 β 为单一常数,在水下复原中需要修正为 $\beta(\lambda)$ (即颜色通道依赖的衰减系数)。

Jaffe-McGlamery模型作为水下光学成像领域最完整和精确的物理模型之一,其优点在于物理机制的完备性和对真实水下环境的精确建模能力。它不仅可用于仿真不同水下环境参数对成像系统的影响,指导水下光学设备的设计和优化,更重要的是,该物理模型为后续的图像增强和质量评价算法提供了坚实的理论基础,许多传统UIQA方法和基于先验的深度学习方法正是利用了这些物理特性设计质

量度量指标。

1.2 主要失真类型与感知表现

水下图像由于水体环境的复杂性,常遭受多种类型的失真,这些失真直接影响图像的视觉质量和后续机器视觉任务的性能。图2展示了一些水下失真类型示例。主要的失真类型及其感知表现如下:

1)颜色偏移与色彩不均一。蓝绿色偏是最常见的水下失真现象,其根源在于海水对不同波长光线的差异性吸收。水体对红光的吸收效率远高于蓝光和绿光,导致图像的红色通道迅速衰减,使得图像整体呈现出不自然的蓝色或绿色主导色调。由于水下光照环境的复杂性(如外部光场和内部介质光)以及水体成分的空间变化(如悬浮物浓度不均),图像的颜色偏差可能在不同区域不一致,这在感知上体现为色彩不均一。这种现象在深水或人工照明条件下尤为明显。

2)低对比度与雾化/浑浊效应。光线在水体中传播时,会受到悬浮颗粒的散射影响,从而导致对比度下降。散射光分为前向散射(导致图像模糊)和后向散射。后向散射光不含场景信息,但被相机接收并叠加在图像上,形成一层类似雾气或光幕的背景光。这层光幕显著降低了景物亮度(直接透射光)和背景亮度之间的对比度,形成雾化/浑浊效应。

3)纹理细节丢失与散斑噪声。纹理细节丢失主要由光线的前向散射和成像系统的运动模糊引起。前向散射使光线偏离原始路径,导致图像中的边缘和纹理变得模糊。散斑噪声通常与水下主动声呐或激光成像系统相关,但在某些条件下,水体中的微小颗粒反射光也可能在图像中产生随机的、类似颗粒的噪声,影响图像的平滑度和感知质量。

4)非均匀照明、闪耀/反光、运动模糊。在使用人工光源或近距离拍摄时,光源强度在场景中的衰减不一致,导致图像中央过亮而边缘过暗,或出现明显的光照不均现象。当光源与光滑水面或物体表面形成特定角度时,可能产生强烈的反射或闪光区域,造成局部过曝。由于水下机器人或相机平台的运动、水流的扰动以及拍摄时较长的曝光时间,都可能导致图像出现运动模糊。

1.3 UIQA与主观感知和任务性能的关系

水下图像质量评价不仅关乎图像的视觉美观度,更与机器视觉系统在水下环境中的实际工作性




图2 水下图像不同失真类型示例

Fig. 2 Examples of different types of distortion in underwater images ((a) green cast; (b) low contrast; (c) texture loss; (d) overexposure)

能紧密相关。理解图像质量与人类主观感知,以及
与下游任务性能之间的关系,是设计有效 UIQA 指
标的关键。

人类视觉系统(human visual system, HVS)对水
下图像质量的感知是多维度的。主要敏感维度包括
色彩自然度、对比度、清晰度和真实感。色彩自然度
反映图像颜色是否符合人眼对水下场景的合理预
期,特别关注颜色偏移(如蓝绿色偏)是否得到有效
校正。对比度和清晰度衡量图像细节的可辨识程
度,与低对比度、雾化效应以及纹理细节丢失直接
相关。真实感是一种更综合的感知维度,它评估图
像在校正失真后,是否仍然保持水下环境的物理合
理性和场景的自然度。UIQA 中的主观评价数据库(如
UWIQA (underwater image quality assessment) (Yang
等, 2021)、UEIQA (image quality assessment database
for underwater image enhancement) (Guo 等, 2022)等)
通过收集人眼对这些维度的评分或排名,建立人类
感知质量标签。

水下图像质量与下游任务(如目标检测、图像分
割、三维重建或水下定位)的性能存在高度相关性。
通常,质量越高的图像,越能提供清晰的边界和准
确的色彩信息,从而有助于机器视觉算法的准确执
行。然而,这种相关性也存在差异性。一个在人类视
觉上被评价为“非常自然”的增强图像,可能由于引
入了不合理的伪影或色彩过度修正,反而导致目标
检测器或分割网络的性能下降。例如,某些任务可能

对颜色信息不敏感,但对边缘和深度信息的准确性
要求更高。因此,研究人员正探索从传统的“主观一
致性”范式转向“任务相关性”的范式融合,即通过质
量—任务联合建模来设计面向任务的质量度量指
标。这种度量指标旨在直接预测或指导水下图像
增强,以最大化下游任务的性能。

2 水下图像质量评价算法常用指标

衡量 UIQA 算法性能常用的指标由视频质量专
家组(video quality experts group, VQEG) (Rohaly 等,
2000)制定,其建议从预测的单调性、预测的准确性
以及预测的一致性3方面衡量客观图像质量评价算
法的性能。在计算以上3个指标之前,VQEG 建议将
客观算法计算的结果拟合到主观质量分数,采用的
非线性拟合函数定义为

$$q(z) = \beta_1 \left(\frac{1}{2} - \frac{1}{1 + \exp(\beta_2 \times (z - \beta_3))} \right) + \beta_4 \times z + \beta_5 \quad (3)$$

式中, z 为由客观算法计算得到的质量分数, $q(z)$
为拟合后的质量分数, $\beta_1 \sim \beta_5$ 为模型参数。

对客观分数拟合之后,VQEG 提出了4个统计指
标来量化客观质量评价算法的预测单调性、准确性
和一致性。其中,预测单调性由斯皮尔曼等级相关
系数(Spearman rank order correlation coefficient,
SRCC)和肯德尔等级相关系数(Kendall's rank order
correlation coefficient, KRCC)表示;预测准确性由皮
尔逊线性相关系数(Pearson linear correlation coeffi-
cient, PLCC)表示;预测的一致性由均方根误差
(root mean square error, RMSE)表示。其中,SRCC 和
KRCC 不受非线性拟合的影响。在以上指标中,
SRCC、KRCC 和 PLCC 计算主观分数与客观分数之
间的相关性,RMSE 计算主观分数与客观分数之间
的误差。因此,SRCC、KRCC 和 PLCC 越接近于1,
RMSE 越接近于0,表示客观质量评价算法的性能
越高。

3 现有 UIQA 和增强数据库

3.1 原始水下图像质量评价数据库

在 UIQA 领域,由于真实场景中几乎无法获取

无失真的参考图像,因此无参考(no-reference, NR)评价方法成为研究的主流。为了有效开发和验证这些NR-UIQA算法,构建带有主观评分的基准数据库至关重要。主观评价通过招募观察者对图像质量进行打分,其结果(通常以平均意见分MOS(mean opinion score)的形式呈现)被视为衡量图像感知质量的“真值”(ground truth, GT)。

图3展示了不同MOS值的水下图像示例,其主观评分范围为0.1~1.0,这类主观标注结果为无参考水下图像质量评价模型的训练与验证提供了关键基准。

近年来,研究人员构建了几个关键的主客观数据库,其中UWIQA、UEIQA和UID2021(underwater image dataset)是代表性的工作,它们在样本规模、失真覆盖和主观标注协议上各有侧重。此外,本文对目前公开发表并广泛引用的UIQA相关数据库进行

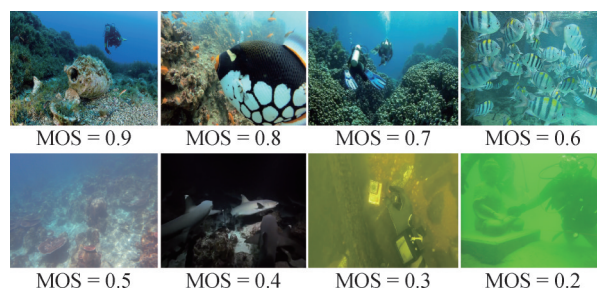


图3 水下图像质量样例及对应主观评分

Fig. 3 Examples of underwater images with corresponding MOS scores

系统梳理、归纳和总结,如表2所示。表2从数据库规模(图像数量)、数据来源(真实采集或算法增强)、是否为配对数据、提出时间以及公开获取方式等多个维度进行对比,旨在为研究人员全面了解现有数据资源的构成特征、适用场景与发展趋势提供清晰的参考。

表2 水下图像数据库清单

Table 2 Underwater image database inventory

名称	规模/幅	来源	是否配对	年份	地址
UIED	1 100	真实世界+增强算法	是	2020	https://github.com/z21110008/UIF
UWIQA	890	真实世界	否	2021	未公开
UID2021	960	真实世界+增强算法	是	2021	https://github.com/Hou-Guojia/UID2021
SAUD	1 100	真实世界+增强算法	是	2022	https://github.com/yia-yuese/SAUD-Dataset
RealUWIQ	1 100	真实世界+增强算法	是	2022	https://github.com/yia-yuese/RealUWIQ-dataset
UEIQA	240	真实世界+增强算法	是	2023	未公开
LSUI	4 279	真实世界+增强算法	是	2023	https://lintaopeng.github.io/_pages/UIE%20Project%20Page.html
URankerSet	8 900	真实世界+增强算法	是	2023	https://github.com/RQ-Wu/UnderwaterRanker
SOTA	32000	真实世界+增强算法	是	2023	https://github.com/Underwater-Lab-SHU/IQA-Datataset
UIQD	5 369	真实世界	否	2024	https://github.com/YT2015?tab=repositories
SAUD2.0	2 600	真实世界+增强算法	是	2025	https://github.com/0117Tzx/MCOLE
OD-UIUA	13 200	真实世界+增强算法	是	2025	未公开
AQUA-UIQD	3 340	真实世界	否	2025	https://github.com/Weiling-Chen/UIQA

3.1.1 UWIQA

UWIQA数据库由Yang等人(2021)构建,旨在为原始水下图像提供一个质量评估基准。该数据库直接利用了公开的水下图像增强基准数据库UIEB(underwater image enhancement benchmark)中的890幅真实水下图像(Li等,2019)。这些图像是在自然光、人造光及混合光照等不同条件下拍摄的,涵盖了广

泛的真实水下场景和固有的质量退化问题,如色彩偏移、低对比度和模糊等。UWIQA的特点在于,它评估的是采集阶段产生的原始图像质量,而非特定增强算法处理后的结果。

研究团队邀请了21名观察者参与主观实验。实验采用单刺激(single stimulus, SS)方法,即每次向观察者呈现1幅图像,要求其对图像的整体质量进

行评分。评分采用5分制(1—差,5—优)。为了确保数据的可靠性,每位观察者进行了两轮有效评分,并对异常数据进行了清洗。最终,将所有有效评分进行平均,并归一化到0.1~1.0的范围内,得到每幅图像的MOS值。该数据库为研究原始水下图像的感知质量特性提供了宝贵的数据支持。

3.1.2 UIQD

UIQD (underwater image quality database) (Liu等, 2024b)旨在解决当前UIQA领域缺乏大型基准数据库的难题。该数据库包含5369幅真实的水下图像,涵盖了丰富的水下场景和典型的质量退化条件,如色偏、低对比度、光照不足等。场景类型非常丰富,包括鱼类、沉船和珊瑚礁等。作者通过大规模主观实验对UIQD中的每幅图像进行了质量感知评分的标注。实验采用了SS方法,要求观察者使用5级评分标准评价图像质量。

UIQD是迄今为止水下图像质量评估研究领域中最大的真实水下图像质量评价数据库。UIQD是一个具有大规模主观质量标注的真实水下图像集合,专为水下图像质量客观评估方法的研究和基准测试而设计。

3.2 增强评测与配对数据库

与3.1节中主要用于主观评价和客观指标验证的数据库不同,本节介绍的数据库其核心目标是为数据驱动的水下图像增强与复原算法(尤其是基于深度学习的模型)提供训练和测试数据。这类数据库的关键特征是包含大量的成对图像,即一幅退化的水下图像和其对应的高质量清晰参考图像。这种配对关系是监督学习模型训练的基础。

3.2.1 UID2021

UID2021数据库由Hou等人(2023)构建,是目前在规模和多样性上最为全面的水下图像增强与复原质量评价数据库之一。它选取了60幅具有代表性的原始水下图像,这些图像被精心划分为6大类典型退化场景:偏蓝、蓝绿、偏绿、模糊、低光照和浑浊。更重要的是,研究者使用了多达15种先进的水下图像增强与复原算法对这60幅原始图像进行处理,生成了900幅增强/复原图像。这15种算法涵盖了传统方法、基于物理模型的方法和基于深度学习的方法。因此,UID2021数据库总共包含960幅图像(60幅原始和900幅处理后),提供了极为丰富的失真类型和质量等级。

UID2021在主观标注上采用了与前两者不同的配对比较排序方案。该方案要求观察者(共52名)从呈现的一对图像中选择质量更好的一方,并允许选择“质量相等”。这种方法降低了观察者进行绝对评分的难度,有助于获得更稳定一致的相对排序。研究人员还为观察者提供了5个评价维度作为参考:色彩失真、对比度、纹理细节、可见度和前景可识别性。实验结束后,通过特定的转换算法将所有配对比较结果整合并转换为0到9范围内的MOS值。UID2021的庞大规模和系统性设计,使其成为训练和测试(尤其是基于深度学习的)NR-UIQA模型的理想基准。

3.2.2 UIED

UIED (underwater image enhancement database) (Zheng等, 2022)解决了当时UIE数据库缺乏人类主观评分的问题,并作为开发和评估水下图像质量客观评价方法的基准。数据库包含了6种典型水下场景,共计100幅真实的原始水下图像,并使用10种具有代表性的UIE算法对原始图像进行增强,以生成用于测试的图像。最后通过主观测试获得了图像的MOS值,并作为客观评价方法的基准。UIED是一个具有大规模主观评分的真实UIE图像集合,旨在推动水下图像增强效果的客观评估研究。

3.2.3 LSUI

为了解决现有数据库在场景多样性和数据规模上的局限,Peng等人(2023)构建了规模更大的LSUI (large scale underwater image)数据库,该数据库特别强调了对基于Transformer的增强模型研究的推动作用。LSUI数据库包含4279组高质量的配对图像。其参考图像的生成过程更为精细:首先,通过18种现有算法处理原始图像,并结合UIQM和UCIQE客观指标初步筛选出前3名;然后,邀请20名专业志愿者对这3幅候选图像进行打分,选出最优者;最后,再通过一轮投票和针对性的后处理(如去噪)对选出的参考图进行二次优化。

除了配对的清晰图像,LSUI的一个显著特点是为每组数据额外提供了语义分割图和介质透射率图。这些额外的标注信息为多任务学习和基于物理模型的深度学习方法提供了宝贵的先验知识。

LSUI的庞大规模和丰富的场景覆盖(如深海、水下洞穴等)使其成为训练复杂深度模型的理想选择。该数据库的提出,旨在促进模型对水下图像中

颜色和空间不一致衰减特性的学习。

3.2.4 RealUWIQ-Dataset

顾约瑟等人(2022)构建了一个用于评估水下图像增强算法性能和图像质量客观评价方法准确性的基准数据库 RealUWIQ-Dataset (real-world underwater image quality dataset), 并通过大规模主观实验对数据进行分析 and 验证。收集了 100 幅真实的原始水下图像作为数据源, 并根据质量退化特点分为色偏主导(60 幅)和模糊主导(40 幅)两组。应用 10 种主流(包括传统和深度学习)的水下图像增强算法对这 100 幅图像进行增强, 共生成 1 000 幅增强后的图像, 为水下图像的增强后质量评价提供了可靠的测试平台。

3.2.5 UEIQA

UEIQA (underwater enhancement image quality assessment) 数据库由 Guo 等人(2022)构建, 其核心目标是评估水下图像增强算法的性能。UEIQA 数据库包含 40 个不同的原始水下场景, 每个场景都经过了 5 种当时具有代表性的图像增强算法处理。具体地, HE (contrast limited adaptive histogram equalization) 基于直方图均衡的对比度增强; DS (decorrelation stretch) 基于去相关拉伸的色彩增强; IF (image fusion) 基于多尺度融合的去雾增强; UDCP (underwater dark channel prior) 基于水下暗通道先验的物理模型复原; NLD (non-local dehazing) 基于非局部去雾的复原。因此, 该数据库包含 40 幅原始图像和 200 幅增强图像, 共 240 幅图像。其失真覆盖面精确地对准了由不同增强算法引入的伪影、色彩过饱和、细节丢失或过度锐化等二次失真。

该研究遵循了更为严格的国际电信联盟 (International Telecommunication Union, ITU) 建议书标准, 邀请了 18 名受试者在受控实验室环境下进行主观评价。实验同样采用 SS 方法, 观察者对每幅图像的质量进行打分。通过计算所有受试者评分的平均值, 得到每幅图像的 MOS 值。UEIQA 的构建为开发专门用于评估增强效果的客观指标 (如其论文中提出的 UWEQM) 提供了关键的训练和验证基础 (Guo 等, 2022)。

3.2.6 SAUD

SAUD (subjectively-annotated UIE benchmark dataset) 数据库由 Jiang 等人(2022)构建, 其核心是为 UIE 算法的性能比较提供一个带有主观排名的基

准。数据库包含 100 个真实水下场景, 每个场景都经过了 10 种具有代表性的 UIE 算法处理, 共生成 1 000 幅增强图像。这些算法涵盖了传统方法和早期的深度学习方法。主观实验采用双刺激配对比较方法, 观察者 (共 75 名) 对同一场景下任意两幅增强图像进行比较, 选出质量更好的一幅。所有配对比较的结果 (共 67 500 个投票) 通过 Bradley-Terry 模型进行处理, 为每个场景中的 10 幅增强图像生成一个全局的主观排名分数。该得分定量地反映了每幅图像在该组内的相对质量位置。

SAUD 的构建旨在支持无参考 UIQA 研究。论文作者基于该数据库提出了一个名为 NUIQ 的客观评价指标, 该指标通过提取颜色和亮度分量的质量感知特征, 并使用 SVMrank 模型进行训练, 其目标是预测与主观排名一致的客观分数。实验证明, 这种基于排名的学习范式比传统的质量分数回归模型在评估增强算法时更具一致性 (Jiang 等, 2022)。之后, 该团队又发布了 SAUD2.0 (Jiang 等, 2025a), SAUD2.0 与 SAUD 数据库相比增加了 100 幅原图, 两种增强算法对其进行处理, 最终得到 2 400 幅增强后的水下图像, 每幅增强后的水下图像均附有它们对应的多维质量标注分数, 包括颜色分数、可见性分数和整体质量分数。

3.2.7 URankerSet

URankerSet 由 Guo 等人 (2023a) 构建, 同样是一个以主观排名为核心的数据库, 旨在训练一个专门用于 UIQA 的排序模型。该数据库基于 UIEB 中的 890 幅原始图像, 并使用了 9 种不同的 UIE 算法进行处理。对于每个场景 (1 幅原始图和 9 幅增强图), 研究团队邀请了 11 名有经验的志愿者进行主观排序。标注过程采用了冒泡排序的思路: 观察者反复比较相邻的两幅图像, 并根据多数投票结果调整其位置, 直到整个序列的顺序稳定下来, 从而得到一个从高到低的感知质量排序。

URankerSet 的主要目的是训练一个名为 URanker 的排序学习模型。URanker 基于 Transformer 架构, 并针对水下图像的特性设计了直方图先验和动态跨尺度对应等模块。模型通过间隔排序损失进行优化, 学习预测与人类主观排序一致的质量顺序。

该研究的一个重要发现是, 一个训练好的、可微的排序模型 (如 URanker) 可以作为一种额外的损失函数指导 UIE 网络的训练。通过将 URanker 的预测

结果反馈给UIE模型,可以促使后者生成在感知质量上排名更高的图像,从而实现“学习如何变得更好”。这一发现为UIE算法的优化开辟了新的思路(Guo等,2023a)。

3.2.8 SOTA

SOTA数据库(state-of-the-art underwater image quality assessment dataset)由Wang(2023)等人提出,旨在全面评估水下增强图像的质量,并特别关注了以往评价指标容易忽略的增强算法所带来的“人为失真”问题。该数据库包含了2000幅具有不同图像内容和退化程度的真实世界水下原始图像。这些图像经过15种极具代表性的UIE算法处理,涵盖了5种传统方法、9种深度学习方法以及1种商业软件(Dive+),最终共生成了30000幅增强图像。整个数据集被统一划分为2000组,每组均包含1幅原图及其对应的15幅增强图像,为全面比较各类算法的增强效果提供了丰富的数据基础。

在主观数据收集方面,SOTA数据库的实验共邀请了25名观察者参与,使用五级连续质量量表对随机展示的图像进行绝对质量打分。打分标准明确要求观察者基于3个维度进行综合考量:偏色程度、雾化效应程度,以及是否引入了过度增强或结构损失等人为失真。收集到的原始评分在经过统计学处理剔除异常值并进行归一化后,取平均值生成了最终的MOS。该绝对分数被统一映射到0~100的区间内,直接作为客观质量评价网络训练与测试的真实标签,定量反映了图像的主观视觉质量。

3.3 数据库构建要点与开放挑战

UIQA数据库是驱动算法创新与性能验证的核心引擎。一个理想的数据库不仅应具备足够的规模,还需在标注可靠性、成像环境多样性以及任务适配性等方面保持高质量。然而,在实践中,从数据标注到应用目标的各个环节都面临显著挑战。本节将围绕数据库构建的核心要素,探讨其关键难点与未来发展方向。

3.3.1 标注规模、主观一致性、跨域泛化与成像环境多样性

在数据库构建过程中,标注规模与质量、主观一致性、跨域泛化能力以及成像环境多样性是相互耦合、彼此制约的核心因素。首先,深度学习模型的性能通常随数据规模的扩大而提升,但水下图像质量标注是一项高成本、劳动密集型工作。为了获取可

靠的MOS值,需要组织大量观测者对海量图像进行打分,这使得现有主流UIQA数据库的规模普遍有限,难以支撑复杂模型的训练,也削弱了模型的泛化能力。

此外,质量评价的主观性带来了标注一致性方面的挑战。不同观测者可能基于不同的视觉偏好(如色彩还原、清晰度或对比度)给出差异化评分,甚至同一观测者在不同状态下的判断也可能不稳定。这种“标签噪声”会干扰模型的特征学习与性能评估,降低其可靠性。为缓解这一问题,未来的研究可从以下两方面展开:一是引入半监督或主动学习策略,在减少人工标注成本的同时提升数据利用效率;二是设计标准化的主观评价流程与鲁棒的分数聚合算法,甚至可将单一总体评分分解为清晰度、色彩、自然度等多个维度,以提高标签的信噪比与表达能力。

另一方面,水下环境的复杂多样性对模型的跨域泛化能力提出了更严峻的挑战。现实中的水下场景千差万别,从清澈的热带海域到浑浊的近岸水域,其光学特性、照明条件与悬浮颗粒浓度均存在显著差异,形成了众多异质“数据域”。任何单一数据库都难以覆盖全部真实场景,因此模型往往会出现“数据域偏移”现象:在训练集上表现良好的模型,面对未知环境时性能显著下降。尽管基于物理模型的合成数据可以一定程度上扩展样本多样性,但“真实鸿沟”问题仍限制了其在实际任务中的有效性。

因此,构建能够全面衡量与提升跨域泛化能力的多域数据库是未来研究重点,需要从全球不同水域、不同深度与光照条件下采集样本,形成覆盖广泛、分层清晰的跨域基准测试集。同时,结合域自适应与域泛化学习策略,使模型能够在有限的标注数据上学习到更具普适性的水下图像质量先验知识,从而在更复杂、更真实的水下环境中保持稳定的性能。

3.3.2 “人类感知 vs 机器任务”两类质量标签的差异与统一

传统水下图像质量评价长期致力于模拟人类视觉系统,以主观偏好和审美体验为核心准则。然而,随着水下探测、生态监测及机器人作业等领域的智能化发展,图像的终端“使用者”已逐渐从人眼转向目标检测、语义分割等计算机视觉算法。这一转变引出了一个根本性矛盾:“人类眼中的高质量”往往

不等同于“机器眼中的高可用”。

这种“感知—任务不一致性”主要源于评价维度的错位:视觉增强算法在提升色彩鲜艳度与对比度以取悦人眼时,常伴随纹理平滑与细节丢失,反而破坏了机器算法所依赖的边缘与结构特征,导致检测或分割性能下降。反之,某些色偏严重但保留了丰富高频信息的图像,虽然在主观审美上得分较低,却能支撑算法获得更高的准确率。显然,单纯依赖MOS已无法客观指导面向机器任务的图像增强与复原,UIQA研究面临着如何在“感知质量”与“任务效用”间寻求平衡的严峻挑战。

为突破这一瓶颈,构建兼具“人类感知评分”与“机器任务性能得分”(如平均精度均值(mean average precision, mAP)、交并比(intersection over union, IoU)等)的“双重标签”数据库成为关键路径。目前,该领域已涌现出两类代表性工作:Liu等人(2025a)构建的OD-UIUA是首个面向目标检测的大规模效用评价数据集。该数据集收录了13 200幅图像(含1 200幅原始图像及经10种算法处理的增强图像),创新性地摒弃了传统MOS,转而采用基于5种经典检测器mAP计算的水下图像效用分数。该工作通过量化分析揭示了一个关键事实:现有增强算法在改善视觉质量的同时,常抑制检测性能,且目前尚无单一算法能通用于所有类型图像。另一重要进展是Chen等人(2025b)建立的以效用为中心的数据库(原文命名为UIQD,为免混淆,本文将标记为AQUA-UIQD)。该库包含3 340幅图像,其标注标准不再基于视觉美感,而是基于鱼类检测任务的“可识别性”(即能否有效检测目标),为效用导向的评价提供了直观基准。

基于此类双模态数据,未来的核心方向是研发“任务感知型UIQA模型”,实现从单一视觉质量评估向机器任务“效用预测”的跨越。最终,该领域旨在建立一套人机协同的统一质量评价框架。该框架将具备根据具体应用场景动态调节权重的能力,在人类感知体验与机器视觉性能之间找到最佳平衡点,从而为水下视觉系统的可靠性验证与智能化升级提供更全面、客观的基准支持。

4 现有水下图像质量评价方法

水下图像质量评价旨在客观衡量水下图像的视

觉质量(郭继昌等,2017b)。水下环境中光线衰减、散射和色偏等因素,会导致图像出现模糊、对比度下降以及颜色失真等问题,UIQA通过设计特征或学习模型,从亮度、清晰度、色彩和结构等方面对图像进行定量评估,从而反映图像的可视性和真实性。各类水下图像质量评估方法的整体分类如图4所示。

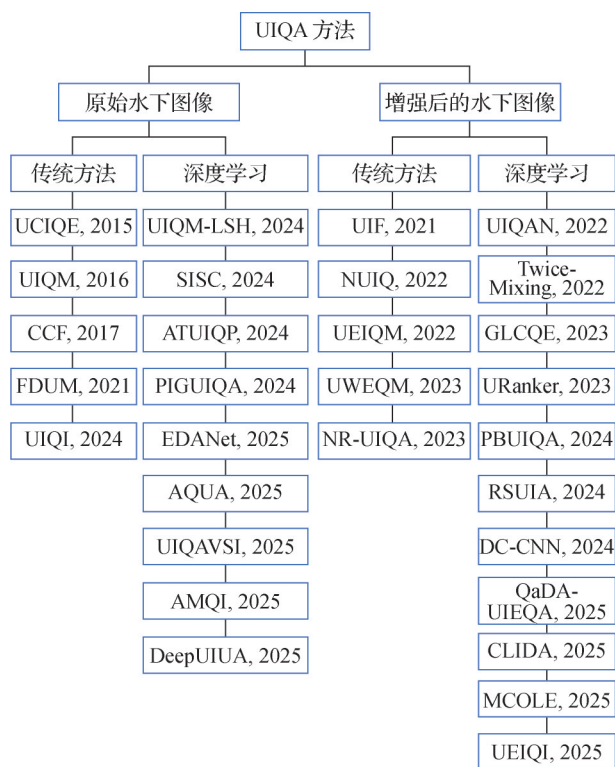


图4 水下图像质量评估方法分类

Fig. 4 Classification of UIQA methods

4.1 原始水下图像质量评价方法

根据原始水下图像质量评价根据建模方式与特征来源的不同,现有方法大体可分为两类:传统的基于特征建模的方法和基于深度学习的端到端方法。前者依赖于显式的视觉特征与水下成像物理机理,具有较强的可解释性;后者则利用深度神经网络自动学习高层语义与感知特征,具备更优的非线性建模与泛化能力。

4.1.1 传统基于特征建模的UIQA方法

传统UIQA方法主要基于图像的低层视觉属性(如色彩、对比度、清晰度等)以及水下成像机理,通过统计特征建模与线性融合实现客观质量预测。代表性方法包括UCIQE(Yang和Sowmya,2015)、UIQM(Panetta等,2016)、CCF(Wang等,2018)、FDUM(frequency domain underwater metric)(Yang等,2021)

与 UIQI (underwater image quality index) (Liu 等, 2024a) 等。

1) 基于颜色与对比度先验的指标。UCIQE 是首个面向水下图像的无参考质量评价指标。该方法在 CIELab 空间中提取色度标准差、亮度对比度及饱和度均值 3 项特征, 并通过线性回归确定权重系数, 实现了对水下偏色与灰雾效应的定量评估。UCIQE 计算为

$$f_{UCIQE} = c_1 \sigma_c + c_2 con_l + c_3 \mu_s \quad (4)$$

式中, σ_c 、 con_l 和 μ_s 分别表示色度标准差、亮度对比度和饱和度平均值, c_1 、 c_2 和 c_3 为相应权重。UCIQE 结构简单、计算高效, 在水下图像增强与复原任务中成为广泛采用的基准。

随后, UIQM 以 HVS 为依据, 从颜色丰满度 (UICM)、清晰度 (UISM) 与对比度 (UIConM) 3 个维度构建质量模型, 通过主观实验确定权重, 实现了对图像自然性与细节层次的综合评估。 f_{UIQM} 计算为

$$f_{UIQM} = c_1 \cdot f_{UICM} + c_2 \cdot f_{UISM} + c_3 \cdot f_{UIConM} \quad (5)$$

式中, c_1 、 c_2 和 c_3 为相应权重。UIQM 以颜色、清晰度和对比度三维特征为核心, 首次构建了适用于水下场景的多特征无参考质量评价框架。该方法在可解释性与主观一致性方面均表现突出, 成为后续水下图像增强与质量评价研究中的经典基准模型。

2) 基于成像物理机理的指标。CCF 指标首次从水下光学吸收与散射机理出发, 将水下图像退化分解为 3 类感知失真: 颜色衰减 (由吸收引起)、模糊 (由前向散射造成) 和雾化 (由后向散射导致)。据此构建了 3 种独立的特征指数: 色彩度指数 $f_{Colorfulness}$ 、对比度指数 $f_{Contrast}$ 与雾密度指数 $f_{Fogdensity}$, 并通过多元线性回归融合为最终的质量分值。该方法以水下成像物理模型为理论基础, 兼具解释性与有效性, 能够同时量化颜色偏差、清晰度与对比度退化, 是传统统计特征方法与感知模型结合的典型代表。CCF 计算为

$$f_{CCF} = \omega_1 \times f_{Colorfulness} + \omega_2 \times f_{Contrast} + \omega_3 \times f_{Fogdensity} \quad (6)$$

式中, ω_1 、 ω_2 和 ω_3 为各指数相应权重。

3) 结合频域与空间域特征的指标。FDUM 在 CCF 框架基础上进一步引入频域分析, 提出了一种结合空间域与频域信息的无参考水下图像质量评价方法。该方法从水下成像的吸收与散射机理出发,

综合考虑颜色失真、对比度降低与清晰度下降 3 类主要退化效应, 构建了 3 个子指标 (色彩度、对比度与清晰度 $f_{Sharpness}$), 并通过多元线性回归得到整体质量分值。该方法首次将频域能量分布引入颜色建模, 同时结合暗通道先验进行对比度量, 有效提升了在复杂光照与高浑浊度场景下的适应性。其计算为

$$f_{FDUM} = \omega_1 \times f_{Colorfulness} + \omega_2 \times f_{Contrast} + \omega_3 \times f_{Sharpness} \quad (7)$$

式中, ω_1 、 ω_2 和 ω_3 为各指标相应权重。

4) 基于统计学习的综合评价模型。UIQI 在前述传统指标的基础上进一步整合亮度、色偏、对比度、清晰度、雾密度及噪声等多维特征, 并采用支持向量回归 (SVR) 学习非线性映射关系, 从而实现了更高的主观一致性与跨数据库泛化性能。该模型标志着传统特征型 UIQA 向统计学习范式的过渡。UIQI 通过显式建模水下图像的多维退化属性, 结合统计学习框架, 实现了全面、客观且可解释的图像质量评价。

与仅关注单一属性的传统方法相比, UIQI 在主观一致性与跨场景稳定性方面均有显著提升, 为水下图像增强与复原研究提供了可靠的客观评价基准。为进一步验证 UIQI 的性能优势, 将其与经典方法 UCIQE 进行了对比, 结果如图 5 所示。可以看出, UIQI 相较于 UCIQE 能够更好地拟合主观评分, 在水下图像质量预测方面表现出更高的准确性与稳定性。

5) 传统方法总结。总体而言, 传统 UIQA 方法遵循“特征构建—线性融合—回归预测”的范式, 具有较高的可解释性与计算效率。这类方法通过人工设计的统计特征刻画水下图像的颜色偏差、对比度下降与清晰度退化等属性, 在早期水下图像质量评估研究中发挥了重要作用。然而, 传统方法普遍存在以下局限性: (1) 对复杂的非线性失真模式建模能力有限, 难以充分捕捉深层次的感知特征; (2) 特征权重通常固定, 缺乏对不同水体类型、光照条件及摄像参数变化的自适应能力; (3) 对于增强算法产生的伪影、色彩过饱和等“感知异常”, 缺乏有效的惩罚机制。因此, 在面对多样化的水下图像增强与复原算法时, UCIQE、UIQM 等传统指标常出现“高分低质”的现象, 即客观得分较高但主观感受较差。这一现象揭示了传统特征型指标在表征复杂水下视觉感知

规律方面的不足,也促使研究者逐步转向基于深度学习的端到端质量建模方法,以期获得更具语义表达力与泛化能力的UIQA框架。




图5 UIQI与UCIQE性能对比

Fig. 5 UIQI vs. UCIQE performance comparison ((a) blur; (b) green cast; (c) low contrast; (d) low luminance)

4.1.2 基于深度学习的UIQA方法

随着深度学习在视觉质量评价领域的迅速发展,研究者开始利用神经网络自动学习从水下图像到主观质量的复杂映射关系。相比依赖人工特征的传统方法,深度模型能够同时捕获低层纹理信息与高层语义特征,从而显著提升对多源退化与增强伪影的感知与建模能力。根据网络结构设计学习目标的不同,现有基于深度学习的UIQA方法大体可分为以下4类:

1)特征融合与感知建模方法。此类方法通过多分支结构设计或特征交互机制实现对多维感知特征的显式分解与融合,提升模型对复杂水下退化的表征与预测能力。代表性研究包括UIQAVSI(underwater image quality assessment method via the fusion of visual and structural information)(Chen等,2025a)、EDANet(deep underwater image quality assessment model with explicit degradation awareness embedding)(Jiang等,2025b)和SISC(self-interaction and side-interaction cross-scale framework)(Chu等,2024)等。

Chen等人(2025a)提出一种多路径深度神经网络模型,即UIQAVSI,通过融合基于HVS的颜色信息与结构信息,实现了对复杂水下图像质量的精确

评估。该方法在网络输入阶段显式分解图像感知特征,分别提取3种互补特征:CIELab图用于反映色彩失真与偏色信息,符合人眼色彩感知规律;梯度图表征结构与清晰度退化,对模糊和散射敏感;去均值对比度归一化(mean subtracted contrast normalized, MSCN)图刻画局部纹理与对比统计规律,用于描述细节变化。在模型架构方面,UIQAVSI采用三支并行网络结构,每个分支独立学习对应的感知特征,实现了颜色、结构与纹理特征的分立表达与协同融合,从而增强了模型的鲁棒性与可解释性。总体而言,UIQAVSI通过显式感知分解与多路径融合机制,提升了模型的自适应能力与可解释性,但其对预定义特征图的依赖较强,泛化性与端到端学习能力仍有限。

Jiang等人(2025b)提出一种基于显式退化感知嵌入的深度水下图像质量评价方法(EDANet),针对现有模型难以区分不同退化模式下质量相似图像的问题,引入与UIE任务相关的退化信息,以提升质量预测的精度与可解释性。EDANet采用两阶段训练策略,包含两个核心子网络:第1个核心子网络是退化信息发现子网络(degradation information discovery sub-network, DIDNet),通过残差学习生成输入图像与伪参考图之间的残差图,用于显式表征局部退化分布(如偏色、模糊、雾化等),并通过嵌入残差通道注意力模块(residual-based channel attention module, RCAM)强化对特定退化模式的响应;第2个核心子网络是退化引导质量评估子网络(degradation-guided quality evaluation sub-network, DQENet),将DIDNet的中间特征嵌入质量评估主干网络,通过降解感知模块(degradation awareness embedding module, DAM)融合多尺度退化与视觉特征,实现局部与全局失真的协同建模,从而生成整体质量分数。EDANet是首个可同时输出局部退化图与整体质量分数的UIQA模型,在兼顾预测精度与可解释性的同时显著增强了退化感知能力。然而,其两阶段训练与伪参考依赖导致模型复杂度与计算成本较高。总体而言,该方法在建立UIE与UIQA任务之间的知识联系方面具有开创性意义,为可解释性深度质量建模提供了新的范式。

Chu等人(2024)提出一种基于特征交互机制的无参考深度UIQA框架(SISC),旨在应对水下图像质量评估中数据稀缺与复杂退化特征难以学习的双重

挑战,通过多层次注意力机制与特征交互策略,实现了在有限样本条件下的高效质量学习。网络结构包含特征提炼与特征增强两个模块。在特征提炼模块中,SISC采用自注意力机制建模局部与非局部特征交互,局部交互用于捕捉细节退化(如局部模糊与伪影),非局部交互用于学习长距离依赖与全局偏色信息,实现纹理与结构层面的综合感知。在特征增强模块中,模型采用跨注意力机制结合上下采样策略实现跨尺度特征融合,低层细节与高层语义特征在不同分辨率下的信息交换提升了模型的鲁棒性与多尺度感知能力。SISC通过“自注意力+跨注意力”特征交互范式,显著提升了特征表达与质量感知能力,在小规模数据库亦能取得与主流模型相当的性能,有效缓解了标注稀缺问题,为轻量化与多尺度UIQA模型研究提供了新的思路。

综上所述,特征融合与感知建模类方法通过多源特征的显式分解、融合与交互学习,显著增强了深

度UIQA模型对复杂水下退化的表征能力与预测精度。这类方法在感知一致性与可解释性方面取得了显著进展,但仍面临模型复杂度高、训练成本大及特征依赖性强等挑战。

2)基于注意力的Transformer与Mamba的综合建模方法。近年来,注意力机制与Transformer架构在高层视觉表征与非局部依赖建模方面展现出显著优势,逐渐被引入UIQA领域,以实现局部与全局感知特征的协同建模。代表性工作ATUIQP (attention-based Transformer for underwater image quality prediction) (Liu等,2024b)提出了一种结合多尺度注意力机制与Transformer的端到端深度UIQA框架,旨在解决水下图像质量评估中高质量基准数据库匮乏以及客观预测模型精度不足的问题。

如图6所示,ATUIQP采用双分支并行结构,以实现局部与全局质量特征的联合建模。

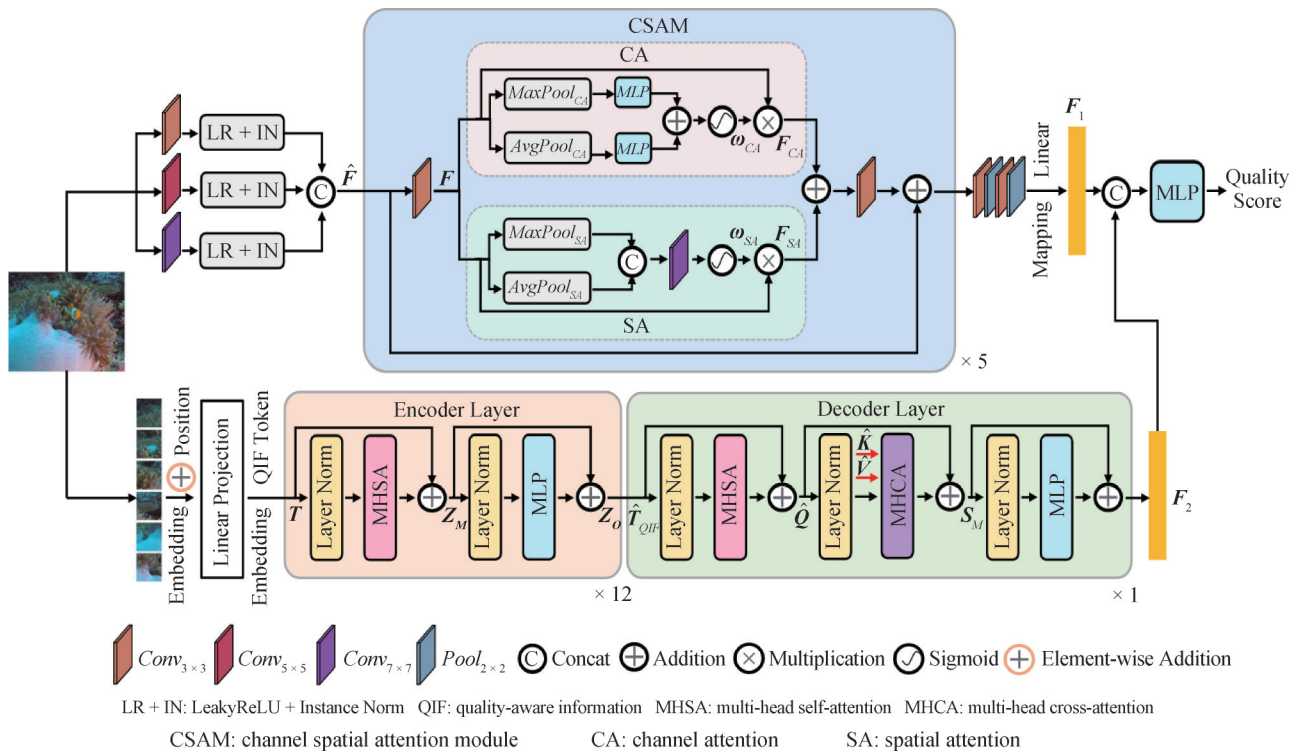


图6 ATUIQP评估模型总览图(Liu等,2024b)

Fig. 6 Overview of ATUIQP evaluation model(Liu et al. ,2024b)

在ATUIQP模型中,局部分支侧重于局部失真特征的捕获,通过多尺度卷积感知不同尺度的退化模式,并嵌入通道—空间注意力模块(channel spatial attention module,CSAM)。其中,通道注意力用

于抑制水下图像中常见的偏色现象(如蓝绿色偏移),而空间注意力则用于增强光照不均与结构细节区域的特征响应,从而实现对局部质量敏感区域的精确建模。全局分支基于Transformer的编码—解码

架构,用于建模图像的非局部依赖关系与全局退化特征。编码器部分通过自注意力机制捕获整体语义信息与全局质量变化,而解码器则利用跨注意力机制整合上下文特征,使全局特征在重建阶段对整体质量变化更加敏感。ATUIQP通过局部—全局双分支结构与注意力—Transformer混合建模策略,有效融合了局部纹理与全局结构特征,实现了对多类型退化的高精度端到端质量预测。其核心优势包括:双分支架构实现的全面特征建模、CSAM针对水下典型退化的优化设计,以及端到端可训练性所带来的高主观一致性与自适应能力。然而,多尺度卷积与Transformer模块的引入也带来了模型复杂度与训练成本的提升,对数据规模与计算资源提出了更高要求。总体而言,ATUIQP在结构设计与性能表现上体现了UIQA模型从卷积主导向混合感知建模的重要转变,为基于Transformer的水下图像质量评价研究开辟了新的方向。

为了解决传统CNN难以捕捉全局上下文以及ViT(vision Transformer)计算复杂度高的问题,Cao等人(2025)提出了一种结合注意力机制与Mamba架构的水下图像质量评价模型AMQI。该模型采用了多阶段架构以平衡局部细节与全局语义的表征:在局部信息表征阶段,设计了通道注意力与大核空间注意力机制,以增强模型对水下色偏校正及局部细节丢失的感知能力;在全局信息表征阶段,创新性地集成了视觉状态空间模型(visual state space model, VSSM)与ResNet-50(residual network 50),利用Mamba的线性复杂度特性高效捕获长距离依赖关系与高层语义。

3)与物理模型结合的深度学习UIQA方法。Liu等人(2023)针对传统UIQA方法过度依赖低层视觉特征、难以有效表征图像语义内容的问题,提出了UIQM-LSH(underwater image quality metric with low-level properties and selected high-level semantics),一种融合低层物理属性与高层语义特征的影响力感知融合框架,以实现水下图像质量的综合评估。该方法采用双层特征建模策略:在低层,提取亮度、对比度与清晰度等物理特征,以反映由光吸收与散射引起的退化;在高层,利用预训练深度网络(如VGG、ResNet)的中间层输出提取语义特征,用于描述结构、纹理及整体感知复杂度。在特征融合阶段,UIQM-LSH引入“影响力感知特征”概念,通过最小角回归实

现特征选择与加权平衡,从而防止高维语义特征掩盖低层物理特征的贡献,保证不同感知维度间的协调性。最终,模型采用SVR将融合特征映射为主观均分,实现端到端的无参考水下图像质量预测。UIQM-LSH的主要优势在于同时整合物理与语义特征,兼顾退化机制与人眼感知一致性,并通过特征选择机制提升模型的可解释性与稳健性。然而,该方法的多阶段特征提取与融合过程相对复杂,高层语义特征依赖于陆地场景的预训练模型,在场景差异较大或水下环境极端条件下,泛化能力可能受限。

随后,Xian等人(2025)提出一种将水下成像物理模型与深度学习有效结合的NR-UIQA框架(PIGUIQA),将水下图像质量评价重新定义为一个融合成像机理与感知建模的综合问题。该方法首次在端到端框架中系统性地引入直射衰减(T)和后向散射(B)两个关键物理因素,以实现水下成像退化过程的可解释建模。

在模型设计上,PIGUIQA首先基于水下辐射传输理论,通过预训练的图像估计模块生成传输衰减图 T 与背景散射图 B ,并以矩阵理论形式定义两种局部失真度量。具体为

$$d_1 = \|T - E\|, d_2 = \|B - O\| \quad (8)$$

式中, E 和 O 分别为全1矩阵与零矩阵,代表理想清晰与无雾状态,从而实现了清晰与雾化程度的定量刻画。整体网络采用两级结构:局部失真感知模块与全局感知聚合器。其中,前者聚焦于局部物理退化建模,后者则通过深度特征融合实现全局质量预测。

PIGUIQA实现了物理机理与深度特征的深度融合,兼具物理可解释性与感知自适应能力。其主要优势在于将成像物理参数显式引入深度网络,使质量预测更具物理一致性。然而,模型性能在一定程度上依赖于 T 与 B 映射的估计精度;此外,局部失真度量(d_1, d_2)采用简化的极值策略,可能低估复杂非线性退化特征。总体而言,PIGUIQA开创性地将物理模型引导思想引入UIQA领域,为实现物理可解释、感知一致的深度质量评价提供了新的研究范式。

4)任务引导型质量建模方法。传统UIQA方法主要关注图像的保真度与美学属性,但在水下视觉应用中,图像质量的核心价值在于其对下游任务性能的影响。为此,Chen等人(2025b)首次提出面向

效用的质量评价框架 AQUA (advanced underwater quality by utility assessment), 将图像质量重新定义为“完成视觉任务的能力”。该框架通过“效用质量反馈回路”机制, 采用迁移学习结合 Transformer 的双层结构, 前端从检测网络中提取高层语义特征以引入任务感知能力, 后端建立特征到效用分数的非线性映射。AQUA 有效建立了感知质量与任务性能的桥梁, 但其训练过程相对复杂且对特定任务数据依赖性较强。为了更自动且准确地预测水下图像的效用分数, Liu 等人 (2025a) 提出了 DeepUIUA 评价方法。该模型采用两阶段设计, 旨在引导模型专注于“目标区域”的质量。第 1 阶段为面向目标区域的特征捕获网络, 基于 YOLOX 架构将主干替换为 ResNet-50 以增强特征提取能力, 并引入特征金字塔和路径聚合网络以应对水下图像的多尺度变化与色偏问题, 利用目标检测标签训练网络聚焦于物体区域。第 2 阶段为多尺度质量评价网络, 直接复用第 1 阶段训练好的 ResNet-50 主干提取多尺度特征 (F_a ,

F_b, F_c), 经融合后通过 L_1 损失函数最小化预测值与真实 MOS 之间的差异, 实现了高效的回归预测。

总体而言, AQUA 与 DeepUIUA 通过“任务引导”思想实现了 UIQA 从感知一致性向任务效用一致性的转变, 为面向任务驱动的智能水下图像质量评价提供了新的理论与方法方向。

5) 深度学习方法总结。基于深度学习的水下图像质量评价方法相较传统手工特征模型在性能与泛化能力方面均取得了显著突破。深度模型能够通过多层非线性特征映射自动学习复杂的退化模式与增强伪影特征, 无需依赖人工设计指标, 从而在不同水质条件、光照环境及成像设备下均表现出更强的鲁棒性与跨域适应性。此外, 深度 UIQA 模型具备端到端可微性, 可与 UIE 网络联合训练, 实现基于质量反馈的自适应优化, 为构建感知一致的增强—评价一体化系统提供了新的途径。

为了直观对比不同范式算法的性能差异, 表 3 列出了主流 UIQA 方法在两个代表性公开数据库

表 3 不同方法在 UIQA 数据库上的性能指标比较

Table 3 Comparison of performance metrics of different methods on UIQA datasets

类型	方法	UWIQA 数据库				UIQD 数据库			
		SRCC	KRCC	PLCC	RMSE	SRCC	KRCC	PLCC	RMSE
传统方法	UCIQE	0.627 1	0.486 3	0.626 1	0.118 5	0.754 5	0.562 5	0.774 3	0.615 1
	UIQM	0.596 0	0.456 3	0.592 8	0.122 5	0.793 7	0.607 9	0.786 7	0.600 3
	CCF	0.445 6	0.334 4	0.463 4	0.134 8	0.585 5	0.398 4	0.540 1	0.818 1
	FDUM	0.678 0	0.528 9	0.646 2	0.116 0	0.846 4	0.658 0	0.837 2	0.531 8
	NUIQ	0.694 8	0.549 7	0.721 4	0.104 7				
	URQ	0.372 4	0.273 7	0.352 7	0.142 3	0.593 9	0.439 7	0.566 5	0.800 9
	UIQI	0.742 3	0.591 2	0.741 2	0.102 0	0.835 8	0.640 9	0.838 7	0.529 2
深度学习	GLCQE	0.606 5	0.470 8	0.622 7	0.118 7	0.898 8	0.728 7	0.897 2	0.428 3
	URanker	0.556 8	0.424 3	0.552 4	0.126 3	<i>0.910 8</i>	<i>0.745 2</i>	<i>0.912 7</i>	<i>0.396 3</i>
	ATUIQP	0.661 4	0.519 7	0.666 7	0.113 2	<u>0.919 2</u>	<u>0.757 0</u>	<u>0.918 6</u>	<u>0.383 7</u>
	AMQI	0.681 0	0.532 2	0.680 5	0.110 0	0.947 2	0.805 6	0.951 1	0.299 9
	Twice-Mix	0.472 7	0.350 1	0.442 2	0.128 9	-	-	-	-
	PIGUIQA	0.714 9	0.572 6	0.747 6	0.108 3	-	-	-	-
	EDANet	0.810 4	0.666 1	<u>0.815 6</u>	<u>0.086 0</u>	-	-	-	-
	UIQM-LSH	<i>0.758 0</i>	<i>0.652 8</i>	<i>0.789 0</i>	0.079 0	-	-	-	-
SISC	<u>0.803 0</u>	<u>0.653 6</u>	0.819 1	<i>0.087 6</i>	-	-	-	-	

注: 加粗、下划线、斜体字体分别表示各列最优、次优、第三优结果, “-”表示代码未公开或训练细节未说明。

(UWIQA 和 UIQD)上的预测性能指标。

如表 3 所示,传统的手工特征方法(如 CCF、UCIQE、UIQM)在两个数据库上的表现普遍受限。在 UWIQA 数据库上,这类方法的 SRCC 值大多在 0.4 至 0.6 之间,且在 UIQD 数据库上的预测误差(RMSE)相对较高(如 CCF 达到 0.818 1)。这印证了仅依赖颜色、对比度等低层统计特征的线性组合,难以充分表征水下图像复杂的非线性退化。相比之下,引入支持向量回归等统计学习策略的 UIQI 方法在 UWIQA 上取得了 0.742 3 的 SRCC 值,显著优于传统物理模型方法,体现了多维特征融合与非线性映射在提升主观一致性方面的优势。

在大规模数据库 UIQD 上,深度学习方法的优势进一步扩大,尤其是结合了注意力机制与 Transformer 架构的最新模型展现了极强的泛化能力。AMQI、ATUIQP 和 URanker 在该数据库上的 SRCC 均突破了 0.9,其中 AMQI 更是达到了 0.947 2 的 SRCC 和 0.951 1 的 PLCC,同时保持了最低的 RMSE (0.299 9)。这表明,相较于 GLCQE 等早期深度模型,具备全局语义感知和长距离依赖建模能力的先进网络架构,能够更准确地拟合大规模复杂场景下的人类视觉感知,是未来高精度 UIQA 模型发展的主流方向。

然而,当前深度 UIQA 方法仍面临若干挑战:一方面,模型训练通常依赖大规模高质量标注数据库(如 UIQD、UWIQA 等),而水下主观质量数据的采集成本高、样本分布不均,使模型泛化性易受限制;另一方面,现有网络结构普遍复杂,参数量庞大,计算开销较高,模型的可解释性与轻量化设计仍有待进一步提升。

未来研究可在物理可解释建模、任务引导学习及跨模态融合等方向深化探索,以实现兼顾性能、效率与可解释性的高效 UIQA 体系。

4.2 增强后水下图像质量评价方法(UEIQA)

传统的 UCIQE 与 UIQM 指标,在评估现代水下图像增强算法时,其局限性日益凸显。多项研究发现,这两个指标的评估结果常常与人的主观感受相悖。例如,Zheng 等人(2022)的研究就指出,一些增强后带有明显红色伪影、视觉上并不自然的图像,其 UCIQE 和 UIQM 得分反而更高。Jiang 等人(2022)与 Guo 等人(2022)的量化实验也证实,这两个指标的预测分数与人类主观排序的相关性显著偏低。这暴

露了这些指标的一个系统性偏差:它们过度奖励了色彩饱和度与对比度的提升,却忽视了增强过程可能引入的失真和伪影。问题的根源在于 UCIQE 和 UIQM 的设计理念与模型结构。正如 Jiang 等人(2022)所分析的,它们最初是为量化原始水下图像的自然退化(如色偏、低对比度)而设计,对于现代增强算法可能引入的过度锐化、非自然纹理等复杂失真,缺乏有效的度量能力。此外,Yi 等人(2024)和 Guo 等人(2022)的研究都指出其线性加权的固定特征组合方式,无法模拟人眼在感知图像质量时,对不同视觉属性间复杂、非线性的建模能力。因此,当面对多种水下图像增强技术时,其评估结果的可靠性受到较大限制。

近年来,为应对上述挑战,研究者发展了多种增强后水下图像质量评价方法,表 4 对其中的代表性工作进行了综合对比。

4.2.1 传统基于特征建模的 UEIQA 方法

为克服传统指标的不足,研究者开始探索更为精细的特征工程方法。在早期探索中,Guo 等人(2022)提出了概念验证性的 UEIQM 指标。该方法证明,专门针对水下环境设计的特征组合,比通用指标更具预测能力。它沿用了 UIQM 的框架,融合了色彩度、清晰度和对比度 3 个核心特征,并通过 SVR 模型将这些特征映射为最终的质量分数。

同年,Zheng 等人(2022)从“保真度”视角出发,构建了 UIF 指标。他们认为,理想的增强不仅要提升观感,还必须保持原始图像的结构。因此,UIF 在评估自然度和清晰度的同时,创造性地引入了结构相似性特征。借鉴 SSIM 思想,它计算增强图像与原始图像在局部方差、均值等方面的相似度,以量化增强过程可能引入的结构失真。方法同样采用 SVR 对所有特征进行融合,并在其构建的大规模 UIED 数据库上展现了出色的预测性能。

Jiang 等人(2022)提出的 NUIQ 方法认为色偏、亮度和细节损失是影响质量的核心,因此在对立颜色空间进行了精细的特征提取。该方法利用非对称广义高斯分布和均匀旋转不变局部二值模式等技术,挖掘图像的深层统计规律。然后 NUIQ 首次将排序学习模型(SVMrank)引入该领域,使其目标从预测绝对分数转向对不同增强结果进行正确排序,从而实现算法性能比较与实际应用需求高度契合。

在对整个水下图像集的质量进行评价时,现有

表4 UEIQA方法综合对比

Table 4 Comprehensive comparison of UEIQA methods

模型名称	发表年份	模型类型	预测目标
UIF	2021	传统机器学习(SVR)	质量分数
NUIQ	2022	传统机器学习(SVMrank)	质量排序
UEIQM	2022	传统机器学习(SVR)	质量分数
Twice-Mixing	2022	深度学习(Siamese network)	质量排序
UIQAN	2022	深度学习(U-Net)	质量分数/排序
GLCQE	2023	深度学习(GAN, DenseNet)	质量分数
URanker	2023	深度学习(Transformer)	质量排序
UWEQM	2023	传统机器学习(random forest)	质量分数
NR-UIQA	2024	传统机器学习(SVR)	质量分数
PBUIQA	2024	深度学习(Res-DenseUNet)	质量分数
RSUIA	2024	深度学习(CNN + SVR)	质量分数
DC-CNN	2024	深度学习(CNN)	质量分数
QaDA-UIEQA	2025	深度学习(ResNet-50, Transformer)	质量分数
CLIDA	2025	深度学习(Transformer, DA)	质量分数
MCOLE	2025	深度学习(VGG-11)	质量分数

方法是采用某一质量评价准则的质量分数平均值作为指标,以平均值的高低说明质量增强算法的优劣,但是,非一致性增强的质量分数平均值会随着图像集的变化而产生较大的波动。为了解决上述问题,孙晓帆等人(2018)提出了一个更加具有普适性的水下图像质量评价方法:一致性增强质量评价(consistent enhancement quality assessment, CEQA)方法。所提方法通过对比图像增强前后的质量分数差值,判断增强算法性能的一致性,再通过改变选定的质量分数差值所占权重比例并统一分数制,求出一致性增强的图像集的一致性增强质量评价分数。

Guo等人(2023b)提出了UWEQM指标,深度耦合了水下成像的物理模型与HVS的特性。创新之处在于,一方面引入了基于光学先验估计的透射率图作为物理特征,另一方面构建了包括类迈克尔逊对比度图、显著性局部二值模式和颜色自相关图在内的高级HVS特征。最后,通过随机森林回归模型进行集成预测,提升了模型的鲁棒性。

尽管特征工程日益复杂,但如何利用高质量图像的先验统计信息仍具挑战。为此,Yi等人(2024)

的NR-UIQA方法从色彩度、对比度和可见度3个维度展开。特别是在色彩度评估上,该方法结合了水下图像强度直方图符合瑞利分布的先验知识,综合计算了饱和度、对比度能量、瑞利分布形状参数及K-L(Kullback-Leibler)散度等多个指标,使得特征描述更加全面。

回顾近年来的发展,增强后水下图像的无参考质量评价已从简单的特征加权,演变为深度结合物理模型、视觉感知特性与复杂统计规律的精细化建模。然而,这些方法对人工设计特征的依赖,使其在面对层出不穷的新算法和复杂场景时仍可能遇到性能瓶颈。因此,研究重心正逐渐转向基于深度学习的端到端解决方案。

4.2.2 基于深度学习的UEIQA方法

与依赖固定物理或统计特征的传统方法(如UIQM、UCIQE)相比,基于深度学习的质量评价方法在评估增强后水下图像的感知质量方面展现出显著优势。传统方法难以全面刻画水下图像复杂的非线性退化特性,尤其在面对不同增强算法引入的多样化伪影(如过增强、色彩失真等)时,其评估结果常与人类主观感知存在偏差。深度学习方法通过端到端

的学习范式,能够从大规模数据中自动提取与感知质量高度相关的多层次、高维度特征。这种数据驱动的特性不仅使模型能够识别传统的色偏与清晰度问题,还能更加敏锐地捕捉由增强算法引入的“不自然感”或“伪影”。例如,深度模型可以区分自然的色彩鲜艳与不真实的过饱和,以及真实的细节恢复与锐化造成的振铃效应。因此,在评估的准确性、鲁棒性与泛化能力方面,深度学习方法相较传统指标具有明显优势。

1) 专注同场景多增强结果优劣的排序型评

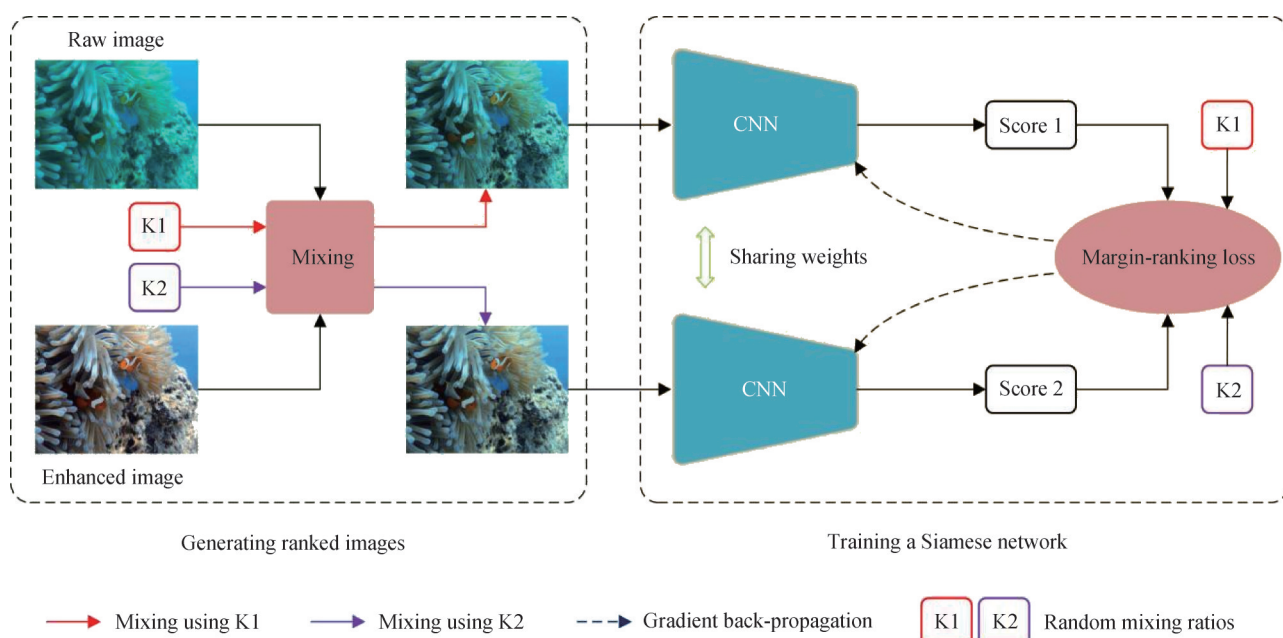


图7 Twice-Mixing 排序型评估模型总览图(Fu等,2022)

Fig. 7 Overview of Twice-Mixing ranking-based evaluation model (Fu et al., 2022)

在此基础上,Guo等人(2023a)提出了URanker模型,该方法以Transformer为核心排序器,创新性地引入直方图先验与动态跨尺度连接,分别用于建模全局颜色分布与局部失真特征。同时,URanker具备可微分特性,可作为感知损失嵌入增强模型的训练过程,实现“评估—生成”一体化闭环优化。

同样,基于排序思想,Zhou等人(2025a)提出了RSUIA模型,将静态评估任务扩展为对动态增强过程的评估。该方法通过混合原始图像与高质量参考图像构建一个质量递增的强化序列,并利用分类器判断待测图像在该序列中的相对位置,从而实现图像质量的动态判别。

2) 利用感知质量网络指导增强网络。此类方法的核心思想是通过构建一个高精度的感知质量评估

估。这类方法将质量评估从困难的绝对分数回归问题,转化为一个更易于学习的相对排序问题,旨在对同一场景下的多种增强结果的优劣进行判别。

Fu等人(2022)提出的Twice-Mixing方法通过将高质量与低质量图像进行两次随机比例混合,生成具有已知排序关系的训练样本,从而以自监督方式学习图像质量排序。该方法利用孪生网络学习相对质量差异,巧妙地绕开了对大规模人工主观分数的依赖,其模型总览如图7所示。

模型,并将其作为可微分的感知损失嵌入水下图像增强网络的训练过程中,从而以质量反馈的方式引导增强结果更符合人类视觉偏好,实现增强与评价的联合优化。

Li等人(2022)提出的UIQAN(underwater image quality assessment network)模型在其HPQ-UIEF(human perceptual quality-driven underwater image enhancement framework)框架中率先实践了这一思路。该方法首先训练一个能够精确预测主观质量分数的评估网络(UIQAN),再将其作为感知损失直接用于指导增强网络的优化,使生成图像的感知质量与人类主观评价保持一致。

3) 其他方法。除了上述主流思路,研究者们还从生成模型、物理先验、域适应与多模态融合等角

度,对增强后水下图像质量评价进行了更具前瞻性的探索。

Wang 等人(2023)提出的 GLCQE (generation-based joint luminance-chrominance underwater image quality evaluation) 框架针对传统指标易误判“过增强”图像的问题,构建了一个基于生成参照的质量评价模型。该方法首先通过双向参考生成模块学习并生成待测图像的“未增强”(V_{re})与“最优增强”(V_{ib})两个版本作为评估锚点。随后,在亮度与色度通道上分别评估结构失真与色彩失真,并通过下式计算图像在“最优增强方向”上的投影长度以量化其质量,具体为

$$Q_I = |V_{re}| \cdot \cos(V_{ib}, V_{re}) \quad (9)$$

该设计确保了增强方向错误(如过增强)的图像会获得较低甚至负分,从而有效提升了评估的判别性与一致性。

Hu 等人(2024)借鉴 Retinex 理论,提出了一种基于双通道卷积神经网络的 UIQA 方法。该方法认为图像质量应从其内在属性进行建模,首先将待测图像 S 分解为反映物体固有颜色的反射分量 R 和包含光照与结构的照度分量 I 。具体为

$$S = R \cdot I \quad (10)$$

然后,设计双通道网络分别从反射分量学习颜色失真特征,从照度分量学习结构退化特征。该种“解耦式学习”策略使模型能够更具针对性地捕捉不同类型的失真,实现了更具可解释性的特征建模。

此外,Wang 等人(2024)提出了一种基于物理先验的评估网络 PBUIQA (prior-based underwater enhanced image quality assessment),其核心思想在于利用水下成像的物理规律辅助质量评估。该方法首先通过一个先验估计网络,从原始水下图像中估计出深度图、衰减系数、环境光等关键物理参数。随后,提出先验引导模块,将包含这些物理信息的特征注入到主评估网络中,为模型提供了超越像素表现的上下文信息,使其能够更深刻地理解图像的退化机理,从而显著提升了对复杂退化机制的理解与评估精度。

在模型跨域泛化能力方面,研究者也进行了深入探索。Wu 等人(2025)为解决 UIQA 模型泛化能力不足的问题,提出 CLIDA (curriculum learning-

inspired domain adaption) 框架。该方法的核心是结合了课程学习与域适应思想,旨在将从大规模有标签的自然图像域中学到的知识,有效迁移至无标签的水下图像域。其关键策略是采用“从易到难”的渐进式学习范式,即首先利用与源域分布最接近的“简单”水下样本进行模型适配,再逐步引入更复杂的样本,从而稳定地提升模型在多样化水下场景中的泛化性能。

Jiang 等人(2025a)则认为单一的整体质量分数不足以全面描述水下图像的复杂质量属性,为此提出了名为 MCOLE (multi-stream collaborative learning) 的“维度丰富”的评估模型。该研究的核心贡献在于构建了一个包含多维度质量标注(如独立的颜色得分、可见度得分和整体得分)的新数据库。在此基础上,设计了一个多流协作学习网络,并行学习这些特定维度的质量特征,最终再将这些特征进行融合以预测整体质量,实现了更加细粒度与全面的评估。

在此基础上,田芷欣和姜求平(2025)提出了 QaDA-UIEQA (quality-aware domain adaptation-based underwater image enhancement quality assessment) 方法。该方法的核心创新在于通过引入多模态信息,使域适应过程具备“质量感知”能力。具体而言,该方法利用描述图像质量属性的文本提示作为引导,通过一个跨注意力模块,将文本特征与图像的视觉特征进行融合。这种文本引导机制使得域适应过程能更专注于与质量相关的特征,从而在面对未知场景或新型增强算法时,表现出更强的鲁棒性和泛化能力。

Liu 等人(2025b)针对现有指标难以充分表征水下增强图像特有的色偏、局部伪影及非自然感等问题,提出了一种基于多维特征解耦与 Transformer 融合的无参考评价指标 UEIQI (underwater enhanced image quality index)。该方法依据增强图像的特性设计了多个专用特征提取分支:利用卷积块注意力模块捕捉通道与局部的色彩失真;通过梯度幅值与 MSCN 系数分别对图像的清晰度、对比度及自然度进行深度特征建模;并构建了频域分析模块以量化残留的雾密度。最后,该模型利用 ViT 强大的全局建模能力,捕获上述不同感知属性间的依赖关系并预测最终质量分数。

4) 基于深度学习的增强后水下图像质量评价总结。综上所述,基于深度学习的增强后水下图像质

量评价方法已逐渐成为研究主流。相较传统的线性加权与人工特征建模思路,深度方法凭借强大的特征学习能力与端到端可微特性,能够自动捕捉多维度、非线性的视觉退化特征,实现了对水下图像“真实感”、“自然度”与“结构保真度”的统一

刻画。

为了验证不同评价指标在衡量增强后水下图像质量方面的有效性,对各方法在3个包含增强图像的主流数据库(UID2021、SAUD和SOTA)上进行性能对比,结果如表5所示。

表5 不同方法在UEIQA数据库上的预测性能指标比较

Table 5 Comparison of performance metrics of different methods on UEIQA datasets

类型	方法	UID2021 数据库			方法	SAUD 数据库			方法	SOTA 数据库		
		SRCC	KRCC	PLCC		SRCC	KRCC	PLCC		SRCC	KRCC	PLCC
传统方法	CCF	0.193 6	0.131 7	0.183 2	CCF	0.051 9	0.042 4	0.240 9	CCF	0.433 7	0.293 9	0.484 0
	UCIQE	0.556 5	0.402 8	0.597 3	UCIQE	0.195 4	0.128 5	0.448 4	UCIQE	0.142 5	0.090 1	0.457 3
	FDUM	0.571 4	0.407 0	0.590 6	FDUM	0.144 5	0.094 6	0.286 5	FDUM	0.042 5	0.025 5	0.249 5
	UIQM	0.271 7	0.184 9	0.320 4	UIQM	0.028 3	0.017 8	0.084 9	UIQM	0.145 3	0.099 1	0.104 4
	UIQI	0.380 5	0.266 4	0.407 1	UIQI	0.127 0	0.084 8	0.205 0	UIQI	0.059 1	0.041 1	0.233 3
	NUIQ	0.063 9	0.043 1	0.122 6	NR-UIQA	0.816 4	0.632 6	0.817 4	UIF	0.249 0	0.169 2	0.288 8
	UIF	0.081 5	0.048 7	0.227 7	UIF	0.118 5	0.071 6	0.207 3	NUIQ	0.444 2	0.312 5	0.533 5
	NR-UIQA	0.734 7	0.542 0	0.742 3	NUIQ	0.337 9	0.227 0	0.211 2				
深度学习	URanker	0.643 3	0.465 1	0.666 4	URanker	0.736 6	0.563 6	0.725 2	URanker	0.755 6	0.570 2	0.798 3
	GLCQE	0.780 2	0.586 9	0.790 3	GLCQE	0.749 8	0.563 9	0.774 3	ATUIQP	0.687 5	0.502 9	0.734 0
	ATUIQP	0.619 1	0.444 3	0.644 5	ATUIQP	0.452 5	0.318 0	0.520 8	GLCQE	0.799 6	0.613 0	0.837 7
	MCOLE	0.791 5	0.602 4	0.797 7	EDANet	0.851 7	0.745 9	<u>0.879 2</u>	PBUIQA	<u>0.864 3</u>	<u>0.691 4</u>	<u>0.896 7</u>
	PIGUIQA	<u>0.814 6</u>	<u>0.622 5</u>	<u>0.816 2</u>	PBUIQA	0.834 7	0.647 9	0.835 6	UEIQI	0.890 8	0.713 9	0.909 4
	UEIQI	0.933 1	0.788 2	0.932 6	UIQAVSI	0.870 3	0.690 2	0.870 9				
					Twice-Mixing	0.472 9	0.329 5	0.442 8				
					DC-CNN	0.874 1	0.697 1	0.874 4				
				UEIQI	0.891 2	<u>0.719 7</u>	0.916 1					

注:加粗、下划线、斜体字体分别表示各列最优、次优、第三优结果。

在表5中,传统方法(如CCF、UCIQE、UIQM)在评估增强后图像质量时表现出显著的局限性。这些方法最初多针对原始水下图像设计,侧重于色彩丰富度和对比度,因此在面对增强算法引入的伪影、过度锐化或色彩过饱和等复杂失真时,预测准确性大幅下降。例如,在SAUD数据库上,UIQM和CCF的SRCC值极低(仅为0.0283和0.0519),表明它们几乎无法区分不同增强算法的优劣。即便是引入了结构信息的UIF和基于排序学习的NUIQ,在跨数据库测试中也表现出较大的波动,难以提供稳定一致的质量评价。

相比之下,基于深度学习的方法展现了压倒性

的性能优势。URanker和GLCQE通过学习数据驱动的特征表示,在3个数据库上均取得了较高的相关性系数,SRCC普遍超过0.6。特别是最新的UEIQI模型,通过多维特征解耦与Transformer融合策略,在UID2021、SAUD和SOTA数据库上均实现了SOTA级别的性能,SRCC值分别为0.9331、0.8912和0.8908。充分证明了深度学习模型在捕捉增强图像中“自然度”与“伪影”等高层感知特征方面的强大能力,能够更准确地反映人类的主观视觉偏好。

当前研究主要呈现出三大发展方向:1)以排序学习和感知反馈为核心的任务驱动型质量建模,实

现了从“评估”到“优化”的闭环;2)以物理约束与生成建模为代表的可解释质量建模,加强了模型对水下成像机理的理解;3)以域适应与多模态融合为核心的跨域泛化研究,显著提升了模型在不同水域环境与增强算法间的鲁棒性。

未来的 UEIQA 研究可进一步探索物理模型与深度特征的协同建模、多模态语义感知引导以及轻量化与可解释性设计,以构建更符合人类感知规律、具备强泛化能力的智能水下图像质量评价体系。

5 结 语

本文系统梳理了 UIQA 研究的最新进展,回顾了水下成像的物理机理与典型失真特征,总结了主流数据库与质量评价方法的发展脉络,归纳了传统特征建模方法与基于深度学习方法的主要成果与不足。总体来看,UIQA 的发展正从“以感知一致性为中心”的度量范式,逐步向“融合物理规律与任务效用”的综合建模方向演进。尽管研究取得了显著进展,但在数据构建、模型解释性、任务适应性与实际部署等方面仍面临诸多挑战。未来的研究可从以下几个方面深化:

1)数据构建的系统化与任务关联化。构建大规模、跨域以及跨水体类型的水下图像质量数据库,是推动方法性能提升与泛化评估的关键。未来的数据库应从单一主观质量标注拓展至多任务关联标注,如语义分割、目标检测和显著性预测等,实现“质量—语义—任务”一体化标注体系。这不仅有助于从感知层面理解水下图像质量,也为面向任务驱动的质量评价提供坚实数据支撑。

2)物理可解释与数据驱动的深度融合。现有评价方法往往只将物理特征作为一种辅助输入,模型并未真正理解物理退化过程,导致评分依据不够透明。未来的研究不应止步于简单的特征拼接,而应探索基于水下成像方程(如 Jaffe-McGlamery 模型)的结构化评价范式。具体而言,可以利用物理规律指导网络架构设计,将图像复杂的混合失真,拆解为“光线吸收导致的色偏”与“颗粒散射造成的模糊”两个独立维度。例如,通过网络反演透射率或背景光参数,量化浑浊度对画质的具体影响,或引入物理约束损失来规范特征提取过程。这种融合让深度网络不再是“盲目”回归分数,而是能够基于明确的物理

归因给出评价,从而显著提升模型在不同水域环境下的鲁棒性与可信度。

3)面向任务效能的质量评价机制。水下图像质量的核心价值不止于“好看”,更在于“可用”。未来的研究应突破仅依赖主观感知一致性的评价模式,发展面向任务效能的质量模型。通过量化图像对下游任务(如检测、识别、分割等)的性能贡献,实现质量与任务性能的双重最优化,从而建立起“质量—任务—智能行为”的新型闭环体系。

4)轻量化与可部署化的模型设计。当前基于深度学习的 UIQA 模型虽然在预测精度上取得突破,但普遍存在计算量大、推理延迟高的问题,限制了其在水下机器人和实时监测系统中的应用。未来应聚焦轻量化网络结构、知识蒸馏与模型压缩等方向,设计兼具准确性与实时性的 UIQA 算法,使质量评价真正走向智能装备端侧,实现水下视觉系统的自感知与自优化。

综上所述,水下图像质量评价的研究正处于由“感知驱动”向“认知与任务协同驱动”的关键转型期。随着跨模态学习、物理建模与具身智能的持续融合,未来的 UIQA 体系将更加智能化、解释性更强,并在推动自主水下视觉感知与人机协作方面发挥核心作用。

参考文献 (References)

- Cao J C, Zhang B C, Liu Y T, Hu R Z, Gu K, Zhai G T, et al. 2025. Attention and Mamba-driven quality assessment for underwater images. *IEEE Transactions on Multimedia*, 27: 9761-9775 [DOI: 10.1109/TMM.2025.3618571]
- Chen L and Ding D D. 2022. Joint multi-residual learning for underwater image enhancement. *Journal of Image and Graphics*, 27(5): 1577-1588 (陈龙, 丁丹丹. 2022. 多残差联合学习的水下图像增强. *中国图象图形学报*, 27(5): 1577-1588) [DOI: 10.11834/jig.210041]
- Chen T H, Yang X C, Wang T S, Li N X, Zhu S and Ji G L. 2025a. Underwater image quality assessment method via the fusion of visual and structural information. *Signal Processing: Image Communication*, 136: #117285 [DOI: 10.1016/j.image.2025.117285]
- Chen W L, Liao H G, Lin R F, Zhao T S, Gu K and Le Callet P. 2025b. Utility-centered underwater image quality evaluation. *IEEE Journal of Oceanic Engineering*, 50(2): 743-757 [DOI: 10.1109/JOE.2024.3498273]
- Chu X H, Hu R Z, Liu Y T, Cao J C and Xu L J. 2024. SISC: a feature

- interaction-based metric for underwater image quality assessment. *IEEE Journal of Oceanic Engineering*, 49(2): 637-648 [DOI: 10.1109/JOE.2023.3329202]
- Fu Z, Fu X, Huang Y and Ding X. 2022. Twice mixing: a rank learning based quality assessment approach for underwater image enhancement. *Signal Processing: Image Communication*, 102: #116622 [DOI: 10.1016/j.image.2021.116622]
- Fang Y M, Sui X J, Yan J B, Liu X L and Huang L P. 2021. Progress in no-reference image quality assessment. *Journal of Image and Graphics*, 26(2): 265-286 (方玉明, 眭相杰, 鄢杰斌, 刘学林, 黄丽萍). 2021. 无参考图像质量评价研究进展. *中国图象图形学报*, 26(2): 265-286 [DOI: 10.11834/jig.200274]
- Gu Y S, Jiang Q P, Shao F and Gao W. 2022. A real-world quality evaluation dataset for enhanced underwater images. *Journal of Image and Graphics*, 27(5): 1467-1480 (顾约瑟, 姜约平, 邵枫, 高伟). 2022. 面向真实水下图像增强的质量评价数据集. *中国图象图形学报*, 27(5): 1467-1480 [DOI: 10.11834/jig.210303]
- Guo C L, Wu R Q, Jin X, Han L H, Zhang W D, Chai Z, et al. 2023a. Underwater ranker: learn which is better and how to be better//Proceedings of the 37th AAAI Conference on Artificial Intelligence. Washington, USA: AAAI Press: 702-709 [DOI: 10.1609/aaai.v37i1.25147]
- Guo J C, Li C Y, Guo C L and Chen S J. 2017a. Research progress of underwater image enhancement and restoration methods. *Journal of Image and Graphics*, 22(3): 273-287 (郭继昌, 李重仪, 郭春乐, 陈善继). 2017a. 水下图像增强和复原方法研究进展. *中国图象图形学报*, 22(3): 273-287 [DOI: 10.11834/jig.20170301]
- Guo J C, Li C Y, Zhang Y and Gu X Y. 2017b. Quality assessment method for underwater images. *Journal of Image and Graphics*, 22(1): 1-8 (郭继昌, 李重仪, 张艳, 顾翔元). 2017b. 面向水下图像的质量评价方法. *中国图象图形学报*, 22(1): 1-8 [DOI: 10.11834/jig.20170101]
- Guo P F, He L, Liu S Y, Zeng D L and Liu H T. 2022. Underwater image quality assessment: subjective and objective methods. *IEEE Transactions on Multimedia*, 24: 1980-1989 [DOI: 10.1109/TMM.2021.3074825]
- Guo P F, Liu H T, Zeng D L, Xiang T, Li L D and Gu K. 2023b. An underwater image quality assessment metric. *IEEE Transactions on Multimedia*, 25: 5093-5106 [DOI: 10.1109/TMM.2022.3187212]
- Hou G J, Li Y X, Yang H, Li K Q and Pan Z K. 2023. UID2021: an underwater image dataset for evaluation of no-reference quality assessment metrics. *ACM Transactions on Multimedia Computing, Communications and Applications*, 19(4): #151 [DOI: 10.1145/3578584]
- Hu R Z, Luo T, Jiang G W, Lin Z Q and He Z Y. 2024. No-reference quality assessment based on dual-channel convolutional neural network for underwater image enhancement. *Electronics*, 13(22): #4451 [DOI: 10.3390/electronics13224451]
- Jiang Q P, Gu Y S, Li C Y, Cong R M and Shao F. 2022. Underwater image enhancement quality evaluation: benchmark dataset and objective metric. *IEEE Transactions on Circuits and Systems for Video Technology*, 32(9): 5959-5974 [DOI: 10.1109/TCSVT.2022.3164918]
- Jiang Q P, Gu Y S, Wu Z W, Li C Y, Xiong H, Shao F, et al. 2025b. Deep underwater image quality assessment with explicit degradation awareness embedding. *IEEE Transactions on Image Processing*, 34: 1297-1310 [DOI: 10.1109/TIP.2025.3539477]
- Jiang Q P, Yi X, Ouyang L, Zhou J C and Wang Z H. 2025a. Toward dimension-enriched underwater image quality assessment. *IEEE Transactions on Circuits and Systems for Video Technology*, 35(2): 1385-1398 [DOI: 10.1109/TCSVT.2024.3466925]
- Koschmieder H. 1924. Theorie der horizontalen Sichtweite. *Beiträge zur Physik der freien Atmosphäre*, 12: 33-55
- Li M Y, Lin Y F, Shen L Q, Wang Z Y, Wang K and Wang Z Y. 2022. Human perceptual quality driven underwater image enhancement framework. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5634415 [DOI: 10.1109/TGRS.2022.3223083]
- Li C, Guo C L, Ren W Q, Cong R X, Hou J H, Kwong S, et al. 2019. An underwater image enhancement benchmark dataset and beyond. *IEEE Transactions on Image Processing*, 29: 4376-4389 [DOI: 10.1109/TIP.2019.2955241]
- Liu F F, Huang Z H, Xie T R, Hu R Z and Qi B B. 2023. Enhancing underwater image quality assessment with influential perceptual features. *Electronics*, 12(23): #4760 [DOI: 10.3390/electronics12234760]
- Liu J P, Liu Y and Jiang Q P. 2025a. Delving into underwater image utility: benchmark dataset and prediction model. *Remote Sensing*, 17(11): #1906 [DOI: 10.3390/rs17111906]
- Liu Y T, Gu K, Cao J C, Wang S Q, Zhai G T, Dong J Y, et al. 2024a. UIQI: a comprehensive quality evaluation index for underwater images. *IEEE Transactions on Multimedia*, 26: 2560-2573 [DOI: 10.1109/TMM.2023.3301226]
- Liu Y T, Zhang B C, Hu R Z, Gu K, Zhai G T and Dong J Y. 2024b. Underwater image quality assessment: benchmark database and objective method. *IEEE Transactions on Multimedia*, 26: 7734-7747 [DOI: 10.1109/TMM.2024.3371218]
- Liu Y T, Zhang B C, Hu R Z, Gu K, Zhai G T and Dong J Y. 2025b. Deep no-reference quality assessment for underwater enhanced images. *IEEE Transactions on Multimedia*, 27: 9227-9239 [DOI: 10.1109/TMM.2025.3613105]
- McGlamery B L. 1980. A computer model for underwater camera systems//Proceedings Volume 0208, Ocean Optics VI. Monterey, United States: SPIE: 221-231 [DOI: 10.1117/12.958279]
- Panetta K, Gao C and Agaian S. 2016. Human-visual-system-inspired underwater image quality measures. *IEEE Journal of Oceanic Engineering*, 41(3): 541-551 [DOI: 10.1109/JOE.2015.2427840]
- Peng L T, Zhu C L and Bian L H. 2023. U-shape transformer for under-

- water image enhancement. *IEEE Transactions on Image Processing*, 32: 3066-3079 [DOI: 10.1109/TIP.2023.3276332]
- Sun X F, Liu H, Zhang X S, Wu L M and Kuang Q G. 2018. Consistent enhancement assessment for an underwater image set. *Journal of Image and Graphics*, 23(11): 1759-1767 (孙晓帆, 刘浩, 张鑫生, 吴乐明, 况奇刚. 2018. 面向水下图像集的一致性增强评价方法. *中国图象图形学报*, 23(11): 1759-1767) [DOI: 10.11834/jig.180255]
- Rohaly A M, Barrett J, Corriveau P, Antkowiak J, Baina J, Baroncini V, et al. 2000. Final report from the video quality experts group on the validation of objective models of video quality assessment. Geneva, Switzerland: Video Quality Experts Group (VQEG), 9-80
- Tian Z X and Jiang Q P. 2025. Quality-aware domain adaptation for underwater image enhancement quality assessment. *Journal of Signal Processing*, 41(2): 290-301 (田芷欣, 姜求平. 2025. 基于质量感知域适应的水下图像增强质量评价. *信号处理*, 41(2): 290-301) [DOI: 10.12466/xhcl.2025.02.008]
- Wang Y, Li N, Li Z Y, Gu Z R, Zheng H Y, Zheng B, et al. 2018. An imaging-inspired no-reference underwater color image quality assessment metric. *Computers and Electrical Engineering*, 70: 904-913 [DOI: 10.1016/j.compeleceng.2017.12.006]
- Wang Z Y, Shen L Q, Wang Z Y, Lin Y F and Chen J B. 2024. Prior-based underwater enhanced image quality assessment network. *IEEE Journal of Oceanic Engineering*, 49(2): 592-605 [DOI: 10.1109/JOE.2024.3351235]
- Wang Z Y, Shen L Q, Wang Z Y, Lin Y F and Jin Y L. 2023. Generation-based joint luminance-chrominance learning for underwater image quality assessment. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(3): 1123-1139 [DOI: 10.1109/TCSVT.2022.3212788]
- Wu S H, Jiang Q P, Yue G H, Wang S Q and Zhai G T. 2025. Generalizable underwater image quality assessment with curriculum learning-inspired domain adaptation. *IEEE Transactions on Broadcasting*, 71(1): 252-263 [DOI: 10.1109/TBC.2024.3511962]
- Xian W Z, Zhou M L, U L H and Li Z G. 2025. PIGUIQA: a physical imaging guided perceptual framework for underwater image quality assessment [EB/OL]. [2025-11-03]. <https://arxiv.org/pdf/2412.15527.pdf>
- Yan J B, Fang Y M and Liu X L. 2022. The review of distortion-related image quality assessment. *Journal of Image and Graphics*, 27(5): 1430-1466 (鄢杰斌, 方玉明, 刘学林. 2022. 图像质量评价研究综述——从失真的角度. *中国图象图形学报*, 27(5): 1430-1466) [DOI: 10.11834/jig.210790]
- Yang M and Sowmya A. 2015. An underwater color image quality evaluation metric. *IEEE Transactions on Image Processing*, 24(12): 6062-6071 [DOI: 10.1109/TIP.2015.2491020]
- Yang N, Zhong Q H, Li K, Cong R M, Zhao Y and Kwong S. 2021. A reference-free underwater image quality assessment metric in frequency domain. *Signal Processing: Image Communication*, 94: #116218 [DOI: 10.1016/j.image.2021.116218]
- Yi X, Jiang Q P and Zhou W. 2024. No-reference quality assessment of underwater image enhancement. *Displays*, 81: #102586 [DOI: 10.1016/j.displa.2023.102586]
- Zheng Y N, Chen W L, Lin R F, Zhao T S and Le Callet P. 2022. UIF: an objective quality assessment for underwater image enhancement. *IEEE Transactions on Image Processing*, 31: 5456-5468 [DOI: 10.1109/TIP.2022.3196815]
- Zhou J C, Liu C J, Zhang D H, He Z X, Sohel F and Jiang Q P. 2025a. RSUIA: dynamic no-reference underwater image assessment via reinforcement sequences. *IEEE Transactions on Multimedia*, 27: 3542-3555 [DOI: 10.1109/TMM.2025.3535308]
- Zhou L, Liu Q M, Jin K J, Zhao W Y and Zhang W D. 2025b. Research progress of underwater image restoration and enhancement methods. *Journal of Image and Graphics*, 30(1): 51-65 (周玲, 刘庆敏, 金凯杰, 赵文义, 张卫东. 2025. 水下图像复原和增强方法研究进展. *中国图象图形学报*, 30(1): 51-65) [DOI: 10.11834/jig.240050]

作者简介

肖帆,男,硕士研究生,主要研究方向为水下图像质量评价和机器视觉。E-mail: xiaofan@stu.ouc.edu.cn

曹景超,通信作者,男,讲师,硕士生导师,主要研究方向为智能感知、水下视觉、大模型和声呐。

E-mail: caojingchao@ouc.edu.cn

段帅,男,硕士研究生,主要研究方向为图像质量评价和增强。E-mail: duanshuai9866@stu.ouc.edu.cn

王亚领,男,硕士研究生,主要研究方向为图像质量评价和增强。E-mail: wangyaling@stu.ouc.edu.cn

马家绪,男,硕士研究生,主要研究方向为图像质量评价和大模型微调。E-mail: majiaxu@stu.ouc.edu.cn

刘玉涛,男,硕士生导师,主要研究方向为图像质量评价、水下图像质量评价与增强、计算机视觉。

E-mail: liuyutao@ouc.edu.cn

董军宇,男,教授,博士生导师,主要研究方向为计算机视觉、水下智能感知、海洋智能感知和声呐。

E-mail: dongjunyu@ouc.edu.cn