arXiv:2601.00194v1 [cs.CV] 1 Jan 2026

DichroGAN：基于卫星影像的海底空气中颜色复原

Salma Gonz´alez-Sabbagh*迪肯大学 沃恩庞兹，VIC，3216，澳大利亚
s.gonzalezsabbagh@research.deakin.edu.au

Antonio Robles-Kelly阿德莱德大学 阿德莱德，SA，5005，澳大利亚
antonio.robles-kelly@adelaide.edu.au

Shang Gao迪肯大学 沃恩庞兹，VIC，3216，澳大利亚
shang.gao@deakin.edu.au

摘要

由于水柱中光线随深度呈指数衰减，从卫星影像中复原海底在空气中的颜色是一项具有挑战性的任务。在本研究中，我们提出了 DichroGAN，这是一种为此目的设计的条件生成对抗网络（cGAN）。DichroGAN 采用两步同步训练：首先，两个生成器利用高光谱图像立方体估计漫反射和镜面反射，从而获得大气场景辐亮度。接下来，第三个生成器接收生成的场景辐亮度作为输入，其中包含每个光谱波段的特征；同时，第四个生成器估计水下光传输。这些生成器协同工作，根据水下成像方程去除光吸收和散射的影响，复原海底在空气中的颜色。DichroGAN 基于从 PRISMA 卫星影像中获取的紧凑数据集进行训练，该数据集包含彼此对应的 RGB 图像、光谱波段和掩膜。在卫星数据集和水下数据集上开展的大量实验表明，与最先进的水下图像复原技术相比，DichroGAN 达到了具有竞争力的性能。

1 引言

当前，水下探索面临两大挑战。首先，潜水本身存在的风险使得直接开展探索和数据采集十分困难，导致数据集规模有限且较小 [50, 9]。其次，水柱的光学特性会因吸收和散射导致光衰减，使大多数水下图像质量下降并产生偏色[6]。得益于传感器技术和成像平台的进步，如今获取水下图像变得更加容易 [35]。研究人员已开展大量研究，通过颜色校正和扩大数据集规模来提升水下图像质量。这并不令人意外，因为已有研究表明，将颜色校正技术与分类等高级视觉任务相结合 [4] ，在避免过度增强的情况下，可以提升整体性能 [32, 51]。人们已提出许多水下图像增强方法[8, 38], 、图像复原方法 [2, 31], 、深度估计方法 [13, 21],和图像合成方法 [49, 11]。然而，这些方法在不同水体类型间往往难以泛化，同时也难以消除颜色失真，并在大范围内恢复水下物体和海底特征在空气中的真实颜色。

恢复水下表面反射率的一种方法是遥感（RS）。作为遥感的一项关键应用，

*通讯作者

卫星影像为恢复海底的空气中颜色提供了重要数据，并有助于开展大规模环境监测，而无需潜入水中。

请注意，卫星影像与水下影像采用不同的处理技术。卫星图像涉及大气柱（如臭氧、水蒸气）和水柱（如水分子、悬浮颗粒）的影响，通常通过大气柱与水柱校正技术进行校正 [42]。相比之下，水下图像主要处理水柱中的光衰减与散射，这会导致颜色失真。具体而言，卫星影像中的光衰减通常通过海底反射率与水柱深度之间的线性回归进行估算 [34], 而水下成像则假设光强度随距离呈指数衰减 [14]。

在本研究中，我们将漫反射和镜面反射纳入水下图像形成模型（UIFM）[14]，以消除水柱固有的光学效应。为此，我们提出 DichroGAN，这是一种条件生成对抗网络（cGAN），它首先根据这些反射推导出卫星场景辐亮度，随后校正水柱效应并恢复海底在空气中的颜色。图 1 展示了其架构。

我们的主要贡献如下：

(1) 我们提出了 DichroGAN，这是首个旨在去除水柱影响并从卫星影像中恢复空气中海底颜色的条件生成对抗网络（cGAN）[1]。我们的框架采用四个生成器：其中两个利用高光谱图像立方体中的漫反射和镜面反射来求解二色反射模型，从而恢复海底反照率和下行光谱；另外两个通过迁移学习求解 UIFM，以估计海底辐亮度和光传输。

(2) 我们通过大量实验验证了我们的方法，并证明其性能与当前最优方法（SOTA）水下技术相比具有竞争力。

[1]代码和数据集可在此处获取：
https://github.com/SalPGS/DichroGAN

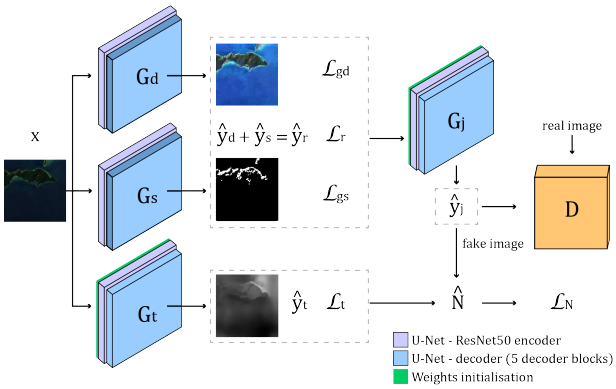

图 1：DichroGAN 概览。它由 4 个生成器和 1 个判别器组成。卫星场景辐亮度通过将 G_d 和 G_s分别生成的漫反射和镜面反射相加得到。生成的辐亮度作为 G_j的输入，而 G_t 则生成深度图以估计光传输。G_j 和 G_t 计算 UIFM[14]，以去除水柱影响并恢复空气中颜色。判别器 D 对生成图像和真实图像进行分类。

2 相关工作

恢复水下场景的空气中颜色，通常采用经验方法或基于物理的方法，并使用传统算法或深度学习算法。

经验方法。Fu 等人 [18] 通过使用颜色校正去除色偏，同时运用 Retinex 理论分解反射率和照明，从而增强水下图像。Luo 等人 [33] 提出了一种基于颜色平衡、对比度优化和直方图拉伸的水下图像复原与去雾算法。其方法保持 RGB 通道的强度分布，以减轻红光吸收。同样，Iqbal 等人 [27] 对 RGB 和 HSV 颜色空间中的像素值进行均衡化，以去除色偏，同时提升对比度和照明。

传统算法。Carlevaris-Bianco 等人 [5]通过分析 RGB通道强度，提出了一种用于深度估计和水下去雾的先验。基于暗通道先验（DCP）[23],，Drews 等人 [13] 开发了水下暗通道先验（UDCP），用于估计深度

并通过仅考虑绿蓝通道强度来复原水下图像。Peng 等人 [44] 使用模糊度和光吸收估计深度，以复原水下辐射亮度。Sea-thru 方法 [2] 基于改进的 UIFM 去除水下场景中的水分 [1]，该方法纳入了漫射下行衰减系数。

深度学习算法。Li 等人 [32] 提出了 Water-Net，这是一种卷积神经网络（CNN），通过融合白平衡、直方图均衡化和伽马校正来增强水下图像。Han 等人 [22] 开发了对比式水下复原（CWR），这是一种受 [28], 启发的条件生成对抗网络方法，采用 ResNet 编码器-解码器生成器和两层感知机生成器，并配备 PatchGAN判别器。Guo 等人 [20]提出了 URanker，这是一种用于评估水下图像质量的基于Transformer的排序器。随后，他们使用预训练 URanker损失训练了 NU^{2}Net（一种 U形网络），用于增强水下图像。最近，Khan 等人 [29]提取相位图像特征，并使用名为 Phaseformer 的基于 Transformer 的网络复原水下图像。

上述大多数方法都依赖水下 RGB 图像。一些研究使用卫星影像，但通常侧重于原位或卫星光谱测量，以估计水柱中的吸收和散射特性以及海底反射率[34, 41, 45, 36]。其他研究则关注去除卫星影像中的雾霾 [30], 云检测 [17], 或水域提取 [54] 。然而，利用卫星影像恢复海底在空气中RGB颜色的研究仍相当少见。

3 方法

3.1 大气中的光传播

光源 $L(\lambda_i)$照射表面辐射为 $I(u,\ \lambda_i)$的物体，物体反射出光谱 $S(u,\ \lambda_i)$，其中编码了该物体的物理和化学性质。根据 Shafer二色反射模型 [47],，物体发出的辐亮度可表示为其在整个电磁波谱范围内的漫反射和镜面反射的线性组合，并纳入索引 i 波长 λ，即 $\lambda_i \in \{\lambda_1, \ldots, \lambda_m\}$，其中 m 是光谱波段的数量：

$$I(u,\lambda_i) = g(u)L(\lambda_i)S(u,\lambda_i) + k(u)L(\lambda_i), \quad (1)$$

其中，u是像素位置，g（u）表示阴影系数，k（u）表示镜面系数。这两个系数都取决于光线方向、视点几何和表面位置。

3.2 水中的光传播

水体中的光传播主要受衰减 α影响。衰减与波长有关，定义为吸收 a和散射 b之和：

$$\alpha(\lambda_i) = a_{pdm}(\lambda_i) + b_{pdm}(\lambda_i), \quad (2)$$

其中，pdm 描述颗粒物和溶解物质的浓度，例如水分子、盐类和叶绿素。衰减还随水深 z、物体到观测者的距离 r以及观测角度（天顶角 θ、方位角 ϕ）[14, 40]而变化。

由于光传播取决于介质，我们采用 Duntley 的 UIFM [14] 来估计水下物体反射 $N(z,\ \theta,\ \phi,\ \lambda_i)$，其表达式为：

$$\begin{aligned} N(z,\theta,\phi,\lambda_i) &= J(z,\theta,\phi,\lambda_i)\exp[-\alpha(z,\lambda_i)r] \\ &+V(z,\theta,\phi,\lambda_i)\exp[K(z,\theta,\phi,\lambda_i)r\cos(\theta)] \\ &\times\{1-\exp[-\alpha(z,\lambda_i)r + K(z,\theta,\phi,\lambda_i)r\cos(\theta)]\}, \end{aligned} \quad (3)$$

其中，$J(z,\ \theta,\ \phi,\ \lambda_i)$ 表示物体辐亮度，$V(z,\ \theta,\ \phi,\ \lambda_i)$ 表示幕光，而 $K(z,\ \theta,\ \phi,\ \lambda_i)$ 是漫衰减系数。

为简化公式 3，我们使用逐元素矩阵运算在图像空间中对其重新表述，得到：

$$\begin{aligned} \mathbf{N}(u,\lambda_i) &= \mathbf{J}(u,\lambda_i)\mathbf{T}(u,\lambda_i) \\ &+\mathbf{V}(u,\lambda_i)(1-\mathbf{T}(u,\lambda_i)), \end{aligned} \quad (4)$$

其中，光传输 $\mathbf{T}(u,\ \lambda_i)$ 描述了光穿过水柱时的指数衰减：

$$\mathbf{T}(u,\lambda_i) = \exp[-r\alpha(z,\lambda_i)]. \quad (5)$$

假设采用正上方（天底）视角，天顶角的余弦值 $\cos(\theta) = 0$，漫衰减系数

K（z，θ，ϕ，λ_i）趋近于零。这简化了公式 4 并使我们能够通过以下方式移除水柱的光学特性：

$$\mathbf{J}(u,\lambda_i)=\left[\frac{\mathbf{N}(u,\lambda_i)-\mathbf{V}(u,\lambda_i)}{\mathbf{T}(u,\lambda_i)}\right]+\mathbf{V}(u,\lambda_i). \quad (6)$$

注意，去除水柱后，$\mathbf{J}(u,\ \lambda_i)$ 根据式$\mathbf{I}(u,\ \lambda_i)$由式1 得到，其中包含海底反照率和下行光谱。我们的方法通过整合二色反射模型，旨在显式分离漫反射和镜面反射。

3.3 DichroGAN 网络

我们采用无监督学习方法，通过首先将观测到的辐亮度分解为其基本组成部分——光源光谱和物体反射率，来解决水生介质固有的歧义。随后，我们校正由吸收和散射导致的水柱畸变，同时保留反射率物理特性，从而恢复表面反照率以及海底的空气中辐亮度。

在我们提出的 DichroGAN 中，我们扩展了标准的条件生成对抗网络 [37, 28]，采用四个生成器和一个判别器 D。生成器 G_d、G_s和 G_t 以一幅 RGB卫星图像作为输入 x，而 G_j 则接收$\hat{}y_r$作为输入，这是由 G_d+G_s 生成的 RGB 预测，从而学习映射 $(\hat{}y_r,\ z)\ \rightarrow\ \hat{}y$。条件生成对抗网络的对抗目标函数如下：

$$\begin{aligned}\min_{\theta_g}\max_{\theta_d}\mathcal{L}_{cGAN}=\mathbb{E}_{x,y}\left[\log D(x,y;\theta_d)\right]+\\ \mathbb{E}_{x,z}\left[\log(1-D(x,\theta_d,G_j(\hat{y}_r,z;\theta_g))\right],\end{aligned} \quad (7)$$

其中 y 是恢复的辐亮度，如公式中所定义。6，且θ_g 和 θ_d 分别是生成器和判别器的参数。

光源估计。我们的首要目标是恢复水覆盖区域的海底辐亮度。我们首先使用公式计算表面辐射。1，并分别通过生成器估计漫反射和镜面反射 G_d和 G_s。为处理照明问题，我们聚焦于光源，并假设满足灰度世界（GW）[15] 假设。我们估计一个均匀的光源光谱 $L(\lambda_i)$，根据包含63个索引光谱波段 λ_i的高光谱图像立方体Im中的平均场景颜色计算得出：

$$L_{gw}(\lambda_i)=\frac{1}{n}\sum_{u\in Im}I(u), \quad (8)$$

其中 n是像素总数。根据公式 1 ，我们可以计算 $k(u)$，即 $^{I}{}_{(u,\ \lambda_i)\ L(\lambda_i)}$。因此，可根据照明光谱和介质特性，求得$k(u)$在各波长上的期望值：

$$\mathbb{E}[k(u)]=\frac{1}{m}\sum_{i=1}^{m}\frac{I(u,\lambda_i)}{L_{gw}(\lambda_i)}. \quad (9)$$

接下来，我们求解阴影因子和表面反射率，其中 $gS(u,\ \lambda_i)\ =g(u)S(u,\ \lambda_i)$：

$$gS(u,\lambda_i)=\frac{I(u,\lambda_i)}{L_{gw}(\lambda_i)}-\mathbb{E}[k(u)]. \quad (10)$$

漫反射与镜面反射的分离。使用 G_d 和 G_s，我们估算漫反射和镜面反射。首先，我们采用线性直方图拉伸提取漫反射和镜面反射的 RGB 值。接下来，我们最小化 G_d 的损失，其中 $\hat{}y_d=G_d(x,\ z;\theta_{gd})$。漫反射率的损失函数定义如下：

$$\mathcal{L}_{gd}=\|L_{gw}(\lambda)g(u)S(u,\lambda)-\hat{y}_d\|_1. \quad (11)$$

同样，我们通过 G_s 估计镜面反射率，其中 $\hat{}y_s=G_s(x,\ z;\theta_{gs})$。镜面反射率的损失函数为：

$$\mathcal{L}_{gs}=\|k(u)L_{gw}(\lambda)-\hat{y}_s\|_1. \quad (12)$$

有了这些要素，我们便能够通过最小化高光谱图像数据立方体与基于 G_d 和 G_s得出的二色反射模型重建结果之间的误差，恢复辐亮度。使用 $L2$范数 [25], ，我们定义：

$$\mathcal{L}_r=m\|I(u,\lambda)-G_s+G_d\|_2. \quad (13)$$

请注意，我们关注的是水覆盖区域的特征，因此通过应用掩码 m忽略陆地区域，该掩码仅惩罚位于

水覆盖区域内的预测。生成的漫反射和镜面反射示例见图2。

雾幕效应和深度图估计。随后，我们将恢复的辐亮度纳入 UIFM（式4），以此聚焦于水介质。幕光 $V_{gw}(u,\lambda_i)$ 通过 GW 获取，而光传输 $T(u,\lambda_i)$ 则使用 [19]中预训练的方法进行估计。

假设处于深水环境且波长依赖性完整，衰减系数设为 0.9。 G_t的损失函数记为 t:

$$t = m\|T(u,\lambda) - \hat{y}_t)\|_1, \tag{14}$$

其中，$\hat{}y_t$ 由 $G_t(x,z;\theta_{gt})$预测。由于我们关注的是水覆盖区域的特征，因此使用 m对陆地区域进行掩膜。为了进一步约束深度估计，我们采用 [16]中的尺度不变损失:

$$\mathcal{L}_t = \log(t+0.5) + \frac{1}{n}\sum_{i=1}(\nabla_x t_i + \nabla_{\hat{y}_t} t_i). \tag{15}$$

生成器 G_j 接收预测的辐亮度$\hat{}y_r$ $=G_s + G_d$，并通过最小化以下项来消除水柱畸变:

$$\mathcal{L}_{gj} = \sum_{i=1}^{n} m\|\mathbf{R}(u,\lambda) - \hat{y}_j)\|_1, \tag{16}$$

其中，$\hat{}y_j$ 由 $G_j(\hat{}y_r, z;\theta_{gj})$预测。

为了进一步约束训练，我们通过在生成域中应用式4 来合成一幅虚假的水下图像:

$$\hat{\mathbf{N}}(u,\lambda) = \hat{\mathbf{y}}_\mathbf{j}\hat{\mathbf{y}}_\mathbf{t} + \mathbf{V_{gw}}(u,\lambda)(1-\hat{\mathbf{y}}_\mathbf{t}). \tag{17}$$

生成的水下图像对应的损失函数为:

$$\mathcal{L}_N = m\|\mathbf{N}(u,\lambda) - \hat{\mathbf{N}}(u,\lambda))\|_1. \tag{18}$$

最后，DichroGan 的总体损失为:

$$\begin{aligned}\mathcal{L}_{obj} = \min_{\theta_g}\max_{\theta_d}\mathcal{L}_{cGAN} + \gamma(\mathcal{L}_{gs} + \mathcal{L}_{gd}) \\ +\sigma\mathcal{L}_r + \iota\mathcal{L}_{gj} + \tau\mathcal{L}_t + \nu\mathcal{L}_N,\end{aligned} \tag{19}$$

其中 γ，σ，ι、 τ 和 ν是用于平衡各损失项的权重。

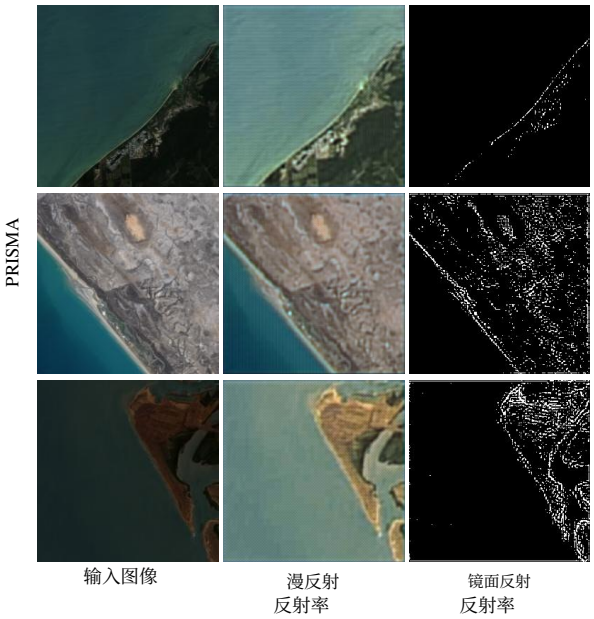

图 2：在 PRISMA 测试数据集上生成的漫反射和镜面反射示例结果。

4 实验与结果

4.1 数据集

我们通过提取并整理 PRISMA（PRecursore IPer-Spettrale della Missione Applicativa）卫星的高光谱观测数据，构建了一个专用数据集。PRISMA 配备了可见光近红外（VNIR）和短波红外（SWIR）光谱仪，以及一台全色相机。该卫星提供空间分辨率为 30 m 的影像 [7]。

我们使用包含地表反射率和可见光近红外光谱范围（400–1010 nm）内 63 个波段的二级产品。通过选取波段 33（R）、45（G）和 56（B）生成 RGB 图像。此外，我们还创建了二值掩膜，将陆地和云（0）与水（1）区分开来。我们的数据集覆盖澳大利亚和墨西哥的地理区域，共包含 1,570 张 RGB 图像，以及对应的光谱波段（98K 张图像）和掩膜。

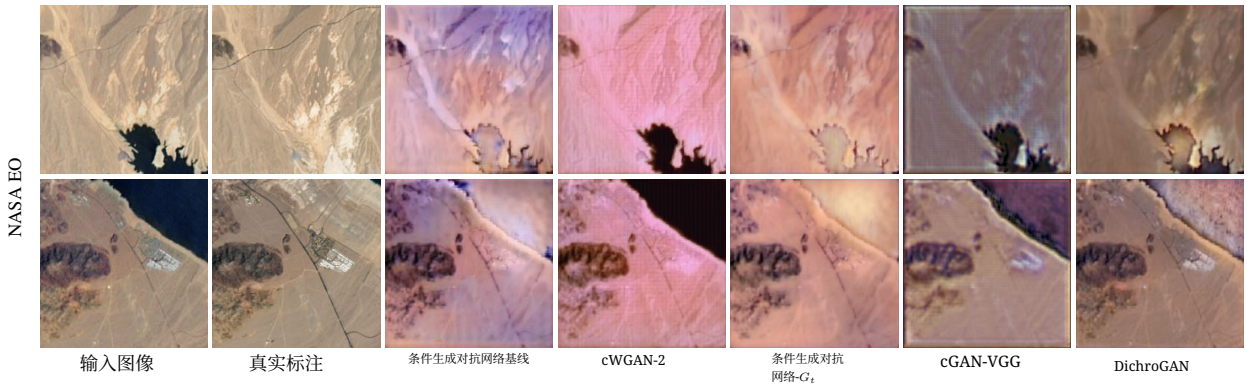

图 3：NASA地球观测数据集上消融实验的示例结果。从左至右：2000 年的米德湖卫星图像（显示高水位的输入图像）和 2022 年的图像（显示干涸区域的真实标注）。后续各列展示了消融实验的结果。

4.2 实现

DichroGAN 由四个生成器和一个判别器组成，并进行同步训练。所有生成模型均采用 U-Net [46] 架构，而判别器则基于 Transformer [12]。生成器采用基于 ResNet 50 [24] 的骨干网络，该网络使用 ImageNet 预训练[10], ，并包含5 个解码器块（256、128、64、32 和 16）。生成器 G_t 和 G_j 使用来自 [19]的预训练权重进行初始化。

我们的方法使用 PyTorch 实现，并在 AMD EPYC 7402P（2.8GHz，24 核）处理器及 60 GB 内存的设备上运行。在所有实验中，输入和输出尺寸均为 $3 \times 256 \times 256$，但生成器 G_s andG_t 除外，它们生成的输出尺寸为 $1 \times 256 \times 256$。我们使用 1,500 张图像及其对应的光谱波段和掩膜进行训练，批量大小设为 6，随机种子固定为 100。训练共进行 130 轮，五个网络采用相同的学习率 0.0002，动量值分别为 0.5 和 0.999。优化使用 Adam优化器。损失函数超参数设置如下：$\gamma = 30$, $\sigma = 90$, $\iota = 100$, $\tau = 50$, and $\nu = 10$。

4.3 评估指标

我们通过定量和定性分析来评估 DichroGAN。首先，我们进行消融研究，以考察其各组成部分的贡献，随后将其与当前最优方法进行比较。对于全参考评价，我们采用结构相似性指数（**SSIM**） [53] 和峰值信噪比（**PSNR**） [26]。对于无参考评价，我们使用自然图像质量评估器（**NIQE**） [39], 、水下图像质量度量（**UIQM**） [43], 和**颜色自然度指标** 度量[52], 对复原后的卫星图像和水下图像进行比较。

4.4 消融研究

我们对基线模型和最终模型进行了比较评估。基线模型采用非同步训练，使用两个相互独立的条件生成对抗网络。在所有实验中，我们使用基于 Transformer 的判别器 D，并对每个生成器采用相同的损失函数。

请注意，脱水和复原后的海底辐亮度 $\hat{}y$由生成器 G_j预测，而水下光传输则由 G_t估算。大气中的表面辐射 $\hat{}y_r$通过对生成器 G_d 和 G_s预测的漫反射和镜面反射求和得到。表1 总结了消融研究及其组成部分。

(1) **条件生成对抗网络基线** 由两个分别训练的条件生成对抗网络组成，并使用二元交叉熵作为对抗损失[28]。第一个条件生成对抗网络（cGAN 1）接收 x 作为输入，由生成器 G_d 和 G_s组成，其输出为 $\hat{}y_r$。该

两个条件生成对抗网络分别训练							
	cGAN 1			cGAN 2			
模型	G_d	G_s	D	G_j	G_t	D_1	对抗损失
条件生成对抗网络基线	✓	✓	✓	✓		✓	交叉熵
条件 Wasserstein 生成对抗网络	✓	✓	✓	✓		✓	EMD
条件生成对抗网络-G_t	✓	✓	✓	✓	✓	✓	交叉熵
单个条件生成对抗网络同步训练							
	cGAN						
模型	G_d	G_s	D	G_j	G_t	D_1	对抗损失
cGAN-VGG	✓	✓	✓	✓	✓		交叉熵
DichroGAN	✓	✓	✓	✓	✓		交叉熵

表1：消融研究。前三个模型由两个分别训练的条件生成对抗网络组成，而最后两个模型由一个包含四个生成器和一个判别器的条件生成对抗网络组成。

第二个条件生成对抗网络（cGAN 2）由一个生成器 G_j 组成，它以 $\hat{}y_r$ 作为输入并生成最终预测结果 $\hat{}y$。每个条件生成对抗网络分别有一个判别器 D 和 D_1。

(2)**cWGANs-2**通过采用两个条件 Wasserstein 生成对抗网络（cWGANs），将二元交叉熵损失替换为地球移动距离 [3], 分别记为 cWGAN1和 cWGAN2。其他所有组件均保持不变。

(3) **cGANs-G**$_t$ 保持 cGAN 1 不变。然而，在 cGAN 2 中，我们在G_j之外引入了第二个生成器 G_t。输入为 $\hat{}y_r$时，最终输出仍为 $\hat{}y$。

(4) **cGAN-VGG**采用同步训练方式，使用一个包含四个生成器和一个判别器 D 的单一 cGAN。x 是 G_d、G_s和 G_t的输入。前两个生成器预测 $\hat{}y_r$，而 G_t 预测 $\hat{}y_t$。生成器 G_j 随后以 $\hat{}y_r$ 为输入，预测去水后的海底反射率 $\hat{}y$。主要目标是优化 $\hat{}y$。所有生成器均采用带有预训练U-Net骨干网络 [19]的 VGG [48] 架构。

表2 展示了我们的消融实验定量结果

消融	$SSIM\uparrow$	$PSNR\uparrow$
条件生成对抗网络基线	0.593	17.75
条件 Wasserstein 生成对抗网络	0.524	17.96
条件生成对抗网络-G_t	0.582	17.78
cGAN-VGG	0.489	16.34
DichroGAN	**0.672**	**18.01**

表2：消融研究的定量评估

方法	$SSIM\uparrow$	$PSNR\uparrow$	$NIQE\downarrow$
UDCP [13]	0.511	11.90	**4.656**
CWR [22]	0.536	13.66	**4.857**
NU^{2}Net [20]	0.535	12.87	5.439
Phaseformer [29]	**0.554**	**13.80**	6.056
Ours	**0.560**	**14.39**	5.643

表3：在 NASA E 上的定量评估 O.

方法	$CCF\uparrow$	$UIQM\uparrow$	$NIQE\downarrow$
输入图像	10.79	1.556	5.813
UDCP [13]	**24.72**	1.395	6.624
CWR [22]	16.91	**2.807**	**4.924**
NU^{2}Net [20]	18.50	**2.878**	5.746
Phaseformer [29]	10.81	2.435	5.759
Ours	**18.84**	2.342	**5.422**

表4：PRISMA 和 NASA EO 上的定量评估。

使用来自NASA地球观测站（EO）项目的卫星影像。我们选取了美国西南部米德湖的影像，重点关注2000年和2022年，以展示水位和裸露地形的变化。

DichroGAN 达到了最高的结构相似性指数和峰值信噪比。图 3 给出了定性比较结果，表明二元交叉熵对抗损失和 U-Net 网络能够带来更好的性能。在两个非同时训练的条件生成对抗网络中，加入第四个生成器 G_t（负责光传输估计）能够改善水柱去除效果，但会略微改变

方法	$CCF\uparrow$	$UIQM\uparrow$	$NIQE\downarrow$
输入图像（HICDR）	14.50	3.091	9.598
UDCP [13]	**33.78**	2.861	10.31
CWR [22]	**43.25**	3.327	**5.918**
NU^{2}Net [20]	29.09	**3.591**	8.047
Phaseformer [29]	22.57	**3.637**	9.488
Ours	25.93	3.351	**5.889**
输入图像（UIEB）	27.50	2.760	4.394
UDCP [13]	**49.71**	2.317	5.474
CWR [22]	20.33	2.975	**3.990**
NU^{2}Net [20]	26.21	**3.278**	4.451
Phaseformer [29]	16.42	**3.327**	5.181
Ours	**26.41**	3.005	**3.987**

表5：在 HICRD [22] 和 UIEB [32]上的定量评估。

究。

场景的整体色彩。相比之下，DichroGAN 能够准确识别并去除水域区域，从而恢复海底的空气中颜色。

4.5 与当前最优方法的比较

据我们所知，目前尚无方法能够专门去除水域区域，并从卫星影像中复原海底在空气中的RGB颜色。因此，为确保比较公平，我们将我们的方法应用于卫星图像和水下图像，以验证实验结果。

为进行比较分析，我们采用水下图像增强与图像复原领域的当前最优方法，包括 UDCP[13], CWR [22], NU^{2}Net [20], 和 Phaseformer [29], ，并结合卫星和水下数据集，包括 PRISMA 的测试集 [7], 、来自 NASA地球观测计划的数据集，以及水下图像增强基准（UIEB） [32], 和苍鹭岛珊瑚礁数据集（HICRD） [22]。总计使用 654 张图像进行比较。

表 3 展示了米德湖图像（NASA EO）上全参考指标的定量结果。我们的方法取得了最高的结构相似性指数和峰值信噪比，数值越高表示性能越好。根据自然图像质量评估器指标，UDCP 方法的图像质量表现最佳，该指标数值越低越好。不过，在定性比较中，如图 3 和 4所示，我们的方法有效去除了水域区域。

表 4展示了 NASA EO 和 PRISMA 数据集上的无参考指标结果。对于 CCF 和 UIQM 指标，数值越高表示性能越好；而对于 NIQE 指标，数值越接近零表示性能越好。我们的方法在 CCF 和 NIQE 指标上均取得第二佳表现，而 UDCP 和 NU^{2}Net 分别取得最佳分数。表 5 展示了水下数据集 HICRD 和 UIEB 上的结果。对于这些数据集，我们的方法取得了最佳 NIQE 分数，而 UDCP、CWR 和 Phaseformer 则在 CCF 和 UIQM 指标上取得最佳分数。

在图 4中，我们将米德湖的真实图像与生成图像进行了比较。结果与定量分析一致，表明我们的方法成功去除了水柱，同时保留了图像结构。其他方法未能准确识别水域区域。PRISMA 和 NASA EO 数据集上的结果见图 5。我们的方法尝试去除水，并还原海底在空气中的颜色，从而更清晰地呈现底层地形。图 6 展示了 HICRD 和 UIEB 数据集上的示例。尽管 UDCP 在水下指标上取得了更高的分数，但它无法消除偏色。

4.6 讨论

目视检查证实，只有 DichroGAN 能够去除偏色。然而，作为一种专注于准确恢复颜色的基于物理的方法，它在标准水下指标上的表现不佳，因为这些指标往往偏向过度增强的图像 [32]。尽管实现了较为合理的一致性，但它也存在一定程度的模糊度，这是生成对抗网络的常见局限，归因于难以学习高频细节。未来工作可着重通过扩大数据集规模来提升性能，并采用多项损失优化来增强纹理和高分辨率映射。

5 结论

在这项工作中，我们介绍了 DichroGAN，这是一种新型条件生成对抗网络，旨在从卫星影像中恢复海底的空气中颜色。通过采用两步同步训练流程，DichroGAN 能够有效估计漫反射和镜面反射，计算大气场景辐射度，并对水下光传输进行建模，以减轻光吸收和散射的影响。实验结果表明，我们的方法在多种卫星和水下数据集上表现出良好的性能。

参考文献

[1] D. Akkaynak 和 T. Treibitz。《修订后的水下图像形成模型》。载于 *IEEE*计算机视觉与模式识别会议论文集，第 6723–6732 页，2018 年。 3[2] D. Akkaynak 和 T. Treibitz。《Sea-thru：一种从水下图像中去除水的方法》。载于 *IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，2019 年 6 月。1，3

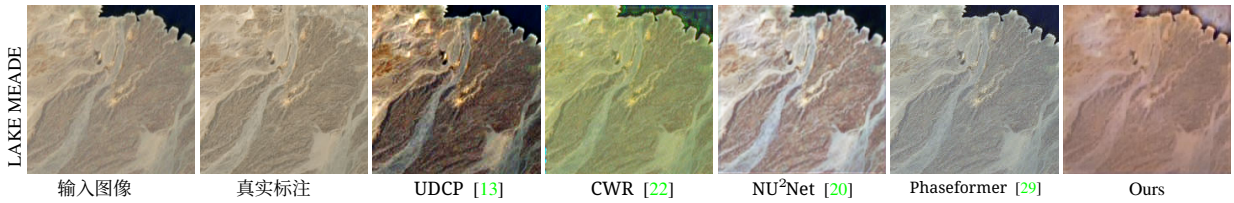

图 4：NASA EO 米德湖图像上的示例结果。

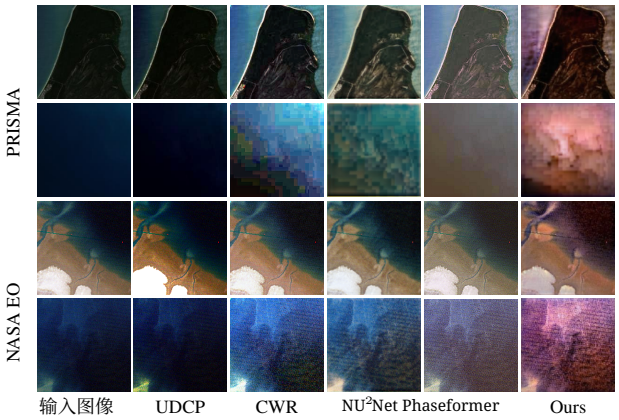

图 5：PRISMA 和 NASA EO 上的示例结果。

[3] M. Arjovsky、S. Chintala 和 L. Bottou。《Wasserstein生成对抗网络》。载于 国际机器学习会议，第 214–223 页。PMLR，2017 年。7[4] T. Boone-Sifuentes、A. Nazari、I. Razzak、M. R. Bouadjenek、A. Robles-Kelly、D. Ierodiaconou 和 E. S. Oh。Marine-tree：用于层次图像分类的大规模海洋生物数据集。载于第 31 届 ACM 信息与知识管理国际会议论文集，第 3838 3842, 2022 1 – 页。[5] N. Carlevaris-Bianco、A. Mohan 和 R. M. Eustice。水下单幅图像去雾的初步结果。载于 Oceans 2010 Mts/IEEE Seattle，第 1 8 2010 2 – 页。IEEE，。L. Chang、H. Song、[6] M. Li 和 M. Xiang。Uidef：真实世界水下图像数据集及色彩对比互补图像增强框架。《ISPRS摄影测量与遥感杂志》，196 415 428, 2023 1 : –。S. Cogliati、F. Sarti、L. [7] Chiarantini、M. Cosi、R. Lorusso、E. Lopinto、F. Miglietta、L. Genesio、L. Guanter、A. Damm 等。PRISMA 成像光谱任务：概述与首次性能分析。《环境遥感》，262 112499，2021 5，8：。[8] R. Cong、W. Yang、W. Zhang、C. Li、C.-L. Guo、Q. Huang 和 S. Kwong。Pugan：利用双判别器生成对抗网络进行物理模型引导的水下图像增强。《IEEE图像处理汇刊》，32 4472 4485, 2023 1 : –。B. Cui、C. [9] Wang、Y. Li、H. Li 和 C. Li。计算机视觉技术在水下混凝土结构损伤检测中的应用。《亚历山大工程学报》，104 745 752, 2024 1 : –。J. [10] Deng、W. Dong、R. Socher、L.-J. Li、K. Li 和 L. Fei-Fei。ImageNet：大型层次图像数据库。载于 IEEE 国际计算机视觉与模式识别会议论文集，第 248–255 页。IEEE，2009。6[11] C. Desai、S. Benur、U. Patil 和 U. Mudenagudi。Rsuigm：利用成像模型生成逼真的合成水下图像。《ACM多媒体计算、通信与应用汇刊》，2024 1 。A. [12] Dosovitskiy、L. Beyer、A. Kolesnikov、D. Weissenborn、X. Zhai、T. Unterthiner、M. Dehghani、M. Minderer、G. Heigold、S. Gelly 等。一张图像胜过 16×16 个词：用于大规模图像识别的 Transformer。arXiv 预印本 arXiv: *2010 11929*, 2020 6 。。[13] P. L. Drews、E. R. Nascimento、S. S. Botelho 和 M. F. M. Campos。基于单幅图像的水下深度估计与图像复原。《IEEE计算机图形学与应用》，36 2 24 35, 2016 1, 2, 7, 8, 9 ( ): –。S. Q. Duntley。海中之光。JOSA, [14] 53 2 214 233, 1963 2, 3 ( ): –。[15] M. Ebner。颜色恒常性，成像科学与技术丛书。约翰·威立父子公司，2007 4 。D. Eigen 和 R. Fergus。利用通 [16] 用多尺度卷积架构预测深度、表面法线和语义标签。载于 IEEE 国际计算机视觉会议论文集，第 2650–2658 页，2015。5

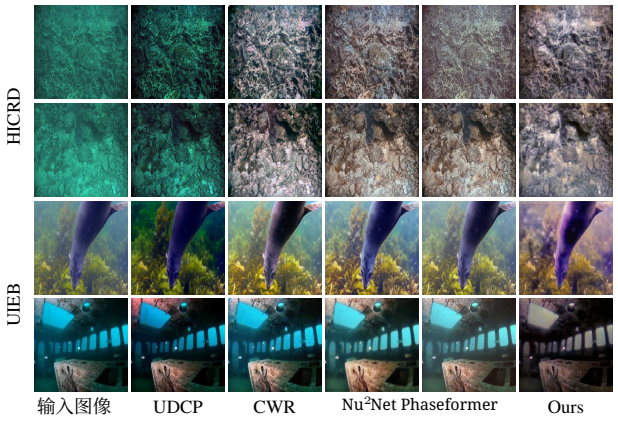

图 6：HICRD 上的示例结果 [22] 和 UIEB [32]。

[17] A. D. Fraser、R. A. Massom 和 K. J. Michael。一种合成极地 MODIS 卫星图像以去除云层覆盖、检测固定海冰的方法。《IEEE地球科学与遥感汇刊》，47(9)：3272–3282，2009。3[18] X. Fu、P. Zhuang、Y. Huang、Y. Liao、X.-P. Zhang 和 X. Ding。一种基于 Retinex 的单幅水下图像增强方法。载于 2014 年 IEEE 国际图像处理会议（ICIP），第 4572–4576 页。IEEE，2014。2[19] S. Gonz´alez-Sabbagh、A. Robles-Kelly 和 S. Gao。Scene-CGAN：用于水下图像复原和场景深度估计的生成对抗网络。《计算机视觉与图像理解》，250：104225，2025。5，6，7[20] C. Guo、R. Wu、X. Jin、L. Han、W. Zhang、Z. Chai 和 C. Li。Underwater Ranker：学习如何判断优劣以及如何做得更好。载于 AAAI 人工智能会议论文集，第 37 卷，第 702–709 页，2023。3，7，8，9[21] H. Gupta 和 K. Mitra。无监督单幅图像水下深度估计。载于 2019 年 IEEE 国际图像处理会议（ICIP），第 624–628 页。IEEE，2019。1[22] J. Han、M. Shoeiby、T. Malthus、E. Botha、J. Anstee、S. Anwar、R. Wei、M. A. Armin、H. Li 和 L. Petersson。通过对比学习和真实世界数据集进行水下图像复原。《遥感》，14(17)：4297，2022。3，7，8，9[23] K. He、J. Sun 和 X. Tang。利用暗通道先验去除单幅图像中的雾。《IEEE模式分析与机器智能汇刊》，33(12)：2341–2353，2010。2[24] K. He、X. Zhang、S. Ren 和 J. Sun。用于图像识别的深度残差学习。载于 IEEE 计算机视觉与模式识别会议论文集，第 770–778 页，2016。6[25] C. P. Huynh 和 A. Robles-Kelly。多光谱光度不变性二色反射模型的一种解法。《国际计算机视觉杂志》，90(1)：1–27，2010。4[26] Q. Huynh-Thu 和 M. Ghanbari。峰值信噪比在图像/视频质量评估中的适用范围。《电子快报》，44 801，2008 13 800 6 ( )：–。[27] K. Iqbal、M. Odetayo、A. James、R. A. Salam 和 A. Z. H. Talib。采用无监督颜色校正方法增强低质量图像。载于 2010 年 IEEE 国际系统、人类与控制论会议，第 1703–1709 页。IEEE，2010。2[28] P. Isola、J.-Y. Zhu、T. Zhou 和 A. A. Efros。利用条件对抗网络进行图像到图像的转换。载于 IEEE 计算机视觉与模式识别会议论文集，第 1125–1134 页，2017。3，4，6[29] R. Khan、A. Negi、A. Kulkarni、S. S. Phutke、S. K. Vipparthi 和 S. Murala。Phaseformer：用于水下图像复原及其他任务的基于相位的注意力机制。载于冬季计算机视觉应用会议（WACV）论文集，第 9600–9611 页，2025年2月。3，7，8，9[30] A. Kulkarni 和 S. Murala。利用注意力可变形 Transformer 进行航空图像去雾。载于 IEEE/CVF 冬季计算机视觉应用会议论文集，第 6305–6314 页，2023。3[31] B. Li、Z. Chen、L. Lu、P. Qi、L. Zhang、Q. Ma、H. Hu、J. Zhai 和 X. Li。水下光学图像复原中的级联框架。《信息融合》，第 102809 页，2024。1[32] C. Li、C. Guo、W. Ren、R. Cong、J. Hou、S. Kwong 和 D. Tao。水下图像增强基准数据集及其拓展。《IEEE图像处理汇刊》，29:4376–4389，2019。1, 3, 7, 8, 9[33] W. Luo、S. Duan 和 J. Zheng。基于融合算法的水下图像复原与增强：色彩平衡、对比度优化和直方图拉伸。《IEEE Access》，9:31792–31804，2021。2[34] D. R. Lyzenga。用于水深和海底特征制图的被动遥感技术。《应用光学》，17(3):379，1978。2, 3[35] A. Marouchos、M. Sherlock 和 J. Cordell。水下图像拍摄面临的挑战。载于 OCEANS 2018 MTS/IEEE Charleston，第 1–5 页。IEEE，2018。1[36] L. I. McKinna、P. R. Fearns、S. J. Weeks、P. J. Werdell、M. Reichstetter、B. A. Franz、D. M. Shea 和 G. C. Feldman。一种半解析海洋颜色反演算法，显式参数化水柱深度和基底反射率。《地球物理研究杂志：海洋》，120(3):1741–1770，2015。3[37] M. Mirza 和 S. Osindero。条件生成对抗网络。arXiv 预印本 arXiv:1411.1784，2014。4[38] P. Mishra、S. K. Vipparthi 和 S. Murala。U-enhance：利用小波三重自注意力进行水下图像增强。载于《亚洲计算机视觉会议论文集》，第 84–101 页，2024。1[39] A. Mittal、R. Soundararajan 和 A. C. Bovik。打造“完全盲”的图像质量分析器。《IEEE信号处理快报》，20(3):209–212，2012。6[40] C. D. Mobley。《光与水：自然水体中的辐射传输》。学术出版社，1994。3[41] J. L. Mueller。《卫星海洋颜色传感器验证海洋光学规程》，第4版：引言、背景与约定，第1卷。戈达德太空飞行中心，2003。3[42] C. Ong。成像光谱用于氧化铁尘埃监测的潜在校准与验证要求。载于 2021 IEEE 国际地球科学与遥感研讨会（IGARSS），第 1619–1622 页。IEEE，2021。2[43] K. Panetta、C. Gao 和 S. Agaian。受人类视觉系统启发的水下图像质量度量。《IEEE海洋工程杂志》，41(3):541–551，2015。6[44] Y.-T. Peng 和 P. C. Cosman。基于图像模糊度和光吸收的水下图像复原。《IEEE图像处理汇刊》，26(4):1579–1594，2017。3[45] M. Reichstetter、P. R. Fearns、S. J. Weeks、L. I. McKinna、C. Roelfsema 和 M. Furnas。珊瑚礁环境中海洋颜色卫星遥感的海底反射率。《遥感》，7(12):16756–16777，2015。3[46] O. Ronneberger、P. Fischer 和 T. Brox。U-Net：用于生物医学图像分割的卷积网络。载于《医学图像计算与计算机辅助干预——MICCAI 2015：第18届国际会议论文集》，德国慕尼黑，2015年10月5日至9日，第III部分18，第234–241页。施普林格，2015。6[47] S. A. Shafer。利用颜色分离反射分量。《色彩研究与应用》，10(4):210–218，1985。3[48] K. Simonyan 和 A. Zisserman。用于大规模图像识别的超深卷积网络。arXiv 预印本 arXiv:1409.1556，2014。7[49] T. Ueda 、 K. Yamada 和 Y. Tanaka。基于 RGB-D 图像的水下图像合成及其在深水下图像中的应用

复原。载于*2019 IEEE*国际图像处理会议（*ICIP*），第 2115–2119 页。IEEE，2019。1[50] C. Wang、C. Cheng、D. Yang、G. Pan 和 F. Zhang。自然场景中的水下自主水下载具导航数据集。*Electronics*，12(18):3788，2023。1[51] Y. Wang、J. Guo、W. He、H. Gao、H. Yue、Z. Zhang 和 C. Li。水下图像增强是否是所有目标检测器所需的？*IEEE*海洋工程杂志，2023。1[52] Y. Wang、N. Li、Z. Li、Z. Gu、H. Zheng、B. Zheng 和 M. Sun。一种受成像启发的无参考水下彩色图像质量评估指标。计算机与电气工程，70:904–913，2018。6[53] Z. Wang、A. C. Bovik、H. R. Sheikh 和 E. P. Simoncelli。图像质量评估：从误差可见性到结构相似性。*IEEE*图像处理汇刊，13(4):600–612，2004。6[54] Y. Zhang、X. Liu、Y. Zhang、X. Ling 和 X. Huang。基于光谱-空间特征和高分一号卫星影像的自动无监督水体提取。*IEEE*地球科学与遥感快报，16(6):927–931，2018。3