Gestão:

Reunião de Acompanhamento e Avaliação - RAA 2026

RESTAURAÇÃO DE ILUMINAÇÃO E TURBIDEZ EM IMAGENS E VÍDEOS SUBAQUÁTICOS.

Schein, T. T.[1]; Oliveira, F. G. [2]; Drews-Jr, P. L.[3]
[1]Bolsista do PRH 22/FURG, Programa de Pós Graduação em Modelagem Computacional – Doutorado, FURG, Rio Grande – RS. E-mail: tatischein@furg.br; [2]Docente no Instituto de Ciências Exatas e Tecnologia da UFAM, Itacoatiara – AM. E-mail: felipeoliveira@ufam.edu.br; [3]Docente no Centro de Ciências Computacionais da FURG, Rio Grande – RS. E-mail: paulodrews@furg.br

INTRODUÇÃO

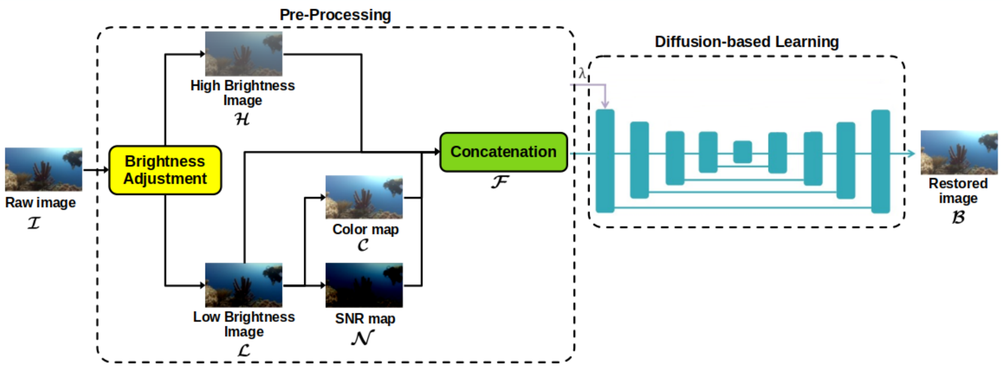
Imagens subaquáticas sofrem com **baixa visibilidade, distorções de cor, perda de contraste e turbidez** devido à absorção e ao espalhamento da luz. A escassez de referências também limita métodos supervisionados, motivando **abordagens autosupervisionadas.**

OBJETIVOS

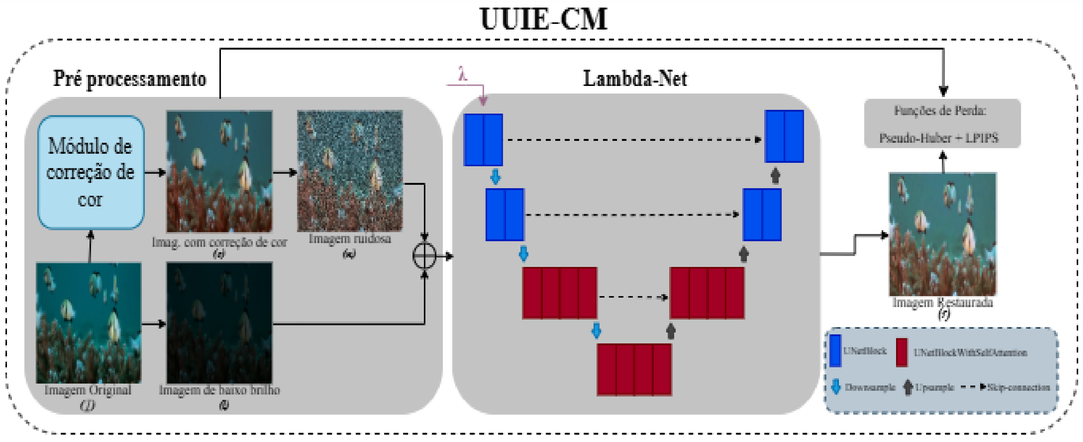
Desenvolver **métodos autosupervisionados** para aprimorar **cor, iluminação e visibilidade** em imagens e vídeos subaquáticos, preservando a naturalidade das cenas e reduzindo o custo computacional.

METODOLOGIA

A pesquisa foi estruturada em duas abordagens autosupervisionadas:
UDBE: utiliza modelos de difusão (DDPM/DDIM) com arquitetura U-Net e condicionamento por mapas de cor e SNR, sua arquitetura esta representada pela Figura a baixo. O treinamento combina funções de perda LPIPS, SSIM, MSE, brilho e cor, visando principalmente à recuperação da iluminação e da qualidade visual.



UUIE-CM: emprega Modelos de Consistência e uma arquitetura condicionada com Lambda-Net, integrando informações de correção de cor e baixa luminosidade, sua arquitetura esta representada pela Figura abaixo. O treinamento utiliza funções de perda Pseudo-Huber e LPIPS, permitindo realizar o aprimoramento em uma única etapa de inferência (*single-step*).
Os métodos foram avaliados nos conjuntos **UIEB, SUIM, RUIE e NUID**, utilizando **métricas de qualidade com e sem referência**. O UUIE-CM também foi validado na **NVIDIA Jetson Orin Nano** para avaliar sua aplicação em sistemas embarcados.



RESULTADOS OBTIDOS

Os resultados demonstraram que as abordagens propostas **melhoram a qualidade de imagens subaquáticas em diferentes condições de degradação.** O UDBE apresentou ganhos principalmente na recuperação da **iluminação e visibilidade**, superando métodos não supervisionados nos conjuntos UIEB, SUIM e RUIE. Na Figura abaixo, a primeira imagem corresponde à entrada, seguida pelos métodos de comparação, e a última apresenta o resultado do UDBE. Os métodos melhoraram a qualidade visual em diferentes condições de degradação. O **UDBE** apresentou maior atuação na recuperação da **iluminação e visibilidade** superando métodos não supervisionados, enquanto o **UUIE-CM** melhorou **cor, contraste e qualidade visual,** com desempenho competitivo frente a métodos supervisionados, como pode ser visto na Tabela da coluna ao lado. No UIEB, alcançou PSNR de 20,30 dB, SSIM de 0,854 e UIQM de 3,3193. Nos conjuntos SUIM e NUID, também apresentou resultados consistentes.



	Método	Conferência&Ano	UIQM↑	UISM↑	UICONM↑	BRISQUE↓	CLIP-IQA↑	PSNR↑	SSIM↑
Não supervisionado	OSMOSIS [60]	ECCV 2024	2,9376	6,5336	0,2088	107,36	0,5097	12,72	0,235
	UESAM [56]	Computers & Graphics 2022	2,9243	**7,2268**	0,1785	71,6013	0,5247	20,13	0,767
	UDBE (Proposto)	ICMLA 2024	2,1383	5,0806	0,1285	66,7676	0,5191	11,95	0,286
	USUIR [20]	AAAI 2022	2,5608	5,4566	0,2238	58,0498	0,5438	17,31	0,764
	UUIE-CM (Proposto)		**3,3193**	6,7629	**0,3276**	**41,4777**	**0,561858**	20,30	0,854
Supervisionado	U-shape [65]	IEEE TIP 2023	3,3096	6,9012	0,3162	62,5456	0,5569	17,33	0,733
	FiveAPlus [35]	BMVC 2023	2,9151	5,4935	0,3193	87,9160	0,5379	21,60	0,882
	LANet [48]	IEEE RA-L 2022	3,0852	6,9255	0,2405	64,6383	0,5457	18,47	0,705
	PUIE NET [21]	ECCV 2022	2,9748	5,9249	0,3007	83,4976	0,5433	22,44	**0,899**
	Phaseformer [38]	WACV 2025	2,9547	5,7699	0,3072	75,5437	0,5482	**22,66**	0,886
	WaveNet [76]	ACM TOMM 2023	2,7165	5,4357	0,2699	86,7958	0,5446	21,24	0,855

Além da qualidade visual, o UUIE-CM reduziu significativamente o custo computacional, demandando 4,33 GFLOPs, frente aos 1202,51 GFLOPs do UDBE. A execução na NVIDIA Jetson Orin Nano (15 W) demonstrou sua **viabilidade para aplicações em tempo real e robótica subaquática embarcada,** os resultados detalhados podem ser vistos na Tabela ao lado. Alguns resultados qualitativos podem ser vistos na Figura abaixo.

	Método	FLOPS↓
Não supervisionado	OSMOSIS [60]	-
	UESAM [56]	-
	UDBE (Proposto)	1202,51 G
	USUIR [20]	14,814 G
	UUIE-CM (Proposto)	4,33 G
Supervisionado	U-shape [65]	2,983 G
	FiveAPlus [35]	**514,369 M**
	LANet [48]	355,193 G
	PUIE-Net [21]	105,799 G
	Phaseformer [38]	13,040 G
	WaveNet [76]	18,148 G

DISCUSSÃO

- O aprendizado **autosupervisionado** mostrou-se uma alternativa viável para o aprimoramento de imagens subaquáticas, reduzindo a dependência de dados pareados.
- O **UDBE** apresentou maior atuação na recuperação da **iluminação,** enquanto o **UUIE-CM** ampliou o aprimoramento para **cor, contraste e qualidade visual.**
- A execução em plataforma **embarcada**, como a NVIDIA Jetson Orin Nano, reforça o potencial para aplicações em robótica e visão computacional subaquática.
- Em **inspeção e monitoramento**, o aprimoramento pode facilitar a interpretação das cenas por operadores e fornecer imagens de melhor qualidade para tarefas automáticas, como **detecção, segmentação e acompanhamento de estruturas.**

REFERÊNCIAS

SCHEIN, Tatiana Taís et al. UDBE: Unsupervised Diffusion-Based Brightness Enhancement in Underwater Images. In: 2024 **International Conference on Machine Learning and Applications (ICMLA).** IEEE, 2024. p. 664–670.
SONG, Yang et al. Consistency Models. In: **Proceedings of the 40th International Conference on Machine Learning (ICML),** 2023.
HO, Jonathan; JAIN, Ajay; ABBEEL, Pieter. Denoising Diffusion Probabilistic Models. **Advances in Neural Information Processing Systems,** v. 33, p. 6840–6851, 2020.
LI, Chongyi et al. An Underwater Image Enhancement Benchmark Dataset and Beyond. **IEEE Transactions on Image Processing,** v. 29, p. 4376–4389, 2020.
SONG, Jiaming; MENG, Chenlin; ERMON, Stefano. **Denoising Diffusion Implicit Models.** arXiv preprint arXiv:2010.02502, 2020.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro do Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis - PRH-ANP, gerido pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2025/03736-5 - Programa PRH-ANP 22/FURG.