

## PLANO DE TRABALHO DE PESQUISA

### 1 – IDENTIFICAÇÃO

Nome do Bolsista MIKAEL PROENÇA STRAUHS	Matrícula 117093918
Título do Programa Sistemas Oceânicos e Tecnologia Submarina para Exploração de Petróleo e Gás e Energias Renovável	
Título do Curso / Especialização Engenharia Naval e Oceânica	
Instituição Universidade Federal do Rio de Janeiro	Sigla UFRJ
Nome do Orientador (1) Jean David Job Emmanuel Marie Caprace	Nome do Orientador (2)

### 2 – TÍTULO DO TRABALHO

Inspeção Autônoma de Dutos Submarinos Utilizando Deep Learning

### 3 – INTRODUÇÃO / OBJETIVO (no máximo 1 página)

Sistemas Subsea estão presentes na maioria dos campos de petróleo no Brasil e no Mundo, possuindo grande relevância para a indústria de óleo e gás. Inspeções desses sistemas com Veículos Autônomos Subaquáticos são altamente efetivos mas demandam extenso recurso humano para analisar todos os dados criados.

Devido ao Elevado volume e complexidade desses dados, grande parte deles não são utilizados ou demandam tempo demais para serem analisados, o que impede sua aplicação em operações em tempo real. Com isso, o uso de inteligência artificial recebe grande valor pelo fato de elevar a velocidade e eficiência do processamento de dados, permitindo que o operador implemente seus resultados na melhoria da operação.

Os objetivos deste trabalho incluem:

- Desenvolver um algoritmo de visão computacional que pode detectar eventos em dutos submarinos a partir de fotos produzidas por inspeções de AUVs (Autonomous Underwater Vehicle)
- Analisar os resultados, identificar a acurácia do algoritmo e realizar as modificações necessárias.
- Embarcar este algoritmo em um AUV de forma que ele possa detectar os eventos durante a inspeção, em tempo quase real.
- Publicações Científicas de artigos e Trabalho de Conclusão de Curso

### 4 – RELEVÂNCIA DO TEMA / JUSTIFICATIVA (no máximo 1 página)

Em uma única viagem de inspeção, um AUV pode gerar centenas de milhares de imagens, o que requer terabytes de espaço de memória. Este valor pode aumentar exponencialmente se considerarmos a inspeção de um campo de petróleo completo. Apesar de haver a possibilidade de se analisar manualmente esses dados, isto requer uma grande equipe de pessoas, trabalhando por um período bastante extenso. Além disso, a probabilidade de erro por fadiga ou distração do operador é elevada.

Por isso, a utilização de Aprendizado Profundo na análise dessas imagens é justificada para a otimização desta operação. Um algoritmo de detecção de objetos bem treinado pode analisar as

imagens geradas pelo AUV em tempo real, identificando eventos que podem afetar negativamente a operação do campo e alertar operadores instantaneamente, provendo informações sobre o problema e sua localização.

#### **5 – ESTADO DA ARTE E METODOLOGIA (no máximo 3 páginas)**

Métodos de Aprendizado Profundo (Deep Learning) são métodos de aprendizado baseados em redes neurais com múltiplas camadas, isto é, com múltiplos níveis de representação, capazes de aprender funções extremamente complexas. Há diversas aplicações como reconhecimento de imagem, reconhecimento de voz, processamento de arte visual e processamento de linguagem natural. Muitas indústrias fazem uso dessa tecnologia atualmente.

Kadampur e Riyae desenvolveram um modelo baseado em aprendizado profundo que foi treinado para classificar imagens de células dermais e detectar câncer de pele, com uma acurácia de 99.77%. A ideia principal deste artigo foi demonstrar que o desenvolvimento de um modelo deste tipo não requer conhecimentos prévios de programação. Os autores utilizaram a ferramenta Deep Learning Studio, que permite desenvolver modelos de aprendizado profundo, de forma simples e totalmente gratuita [1].

Dentre diversas aplicações de reconhecimento de imagem, que incluem classificação de objetos, segmentação de instâncias e estimativa de pose, a utilizada neste trabalho é detecção de objetos. Esta aplicação é adequada pois é capaz de detectar e localizar eventos específicos pelo envolvimento por retângulos, de forma intuitiva e simples ao usuário.

Aprendizado por Máquinas (Machine Learning) e detecção de objetos têm sido utilizados há anos na Indústria Subsea. Diversas empresas e cientistas estão implementando essas tecnologias na tentativa de aprimorar eficiências de projeto, construção e operação.

Redes neurais já estavam sendo utilizadas em sistemas de controle de AUVs em 1991 por Fuji e Ura [2], enquanto Sayyaadi e Ura [3], utilizaram redes neurais na modelação, controle de posição e planejamento de rota 10 anos depois. Em 2003, Alfaro-Cid et al. [4] implementaram algoritmos genéticos para planejar rotas de AUVs e, mais recentemente, Shojaei [5] investigou um problema de rastreamento de alvo tridimensional de AUVs por meio de transformação de coordenadas e redes neurais de múltiplas camadas.

Especificamente no campo de visão computacional subaquática, detecção de objetos por vídeo não é uma ideia nova. Walther et al. [6] desenvolveram, em 2004, um algoritmo para detectar animais em imagens obtidas por Veículos Operados Remotamente ou Remotely Operated Vehicles (ROVs), com erro de 6% quando considera-se somente quadros (frames) singulares. Os autores obtiveram acurácia de 70% para processamento de vídeo, quando comparado à análise manual dos mesmos dados. Apesar disso, não foi utilizado Aprendizado de Máquina, somente processamento de imagem.

Gaya et al. [7] adotaram uma estratégia de evasão de objetos baseada em visão utilizando aprendizado profundo para encontrar regiões de interesse e direções de escape ótimas. Os autores propuseram uma abordagem em tempo real, aplicável para pequenos AUVs equipados com uma única câmera mono ocular e inserido num ambiente oceânico real. Apesar dos bons resultados, não foi possível lograr o objetivo de aplicar em tempo real.

Aprofundando no campo de visão computacional subaquática, abordando aplicações de detecção de

objetos por Aprendizado de Máquina, Kim et al. [8] desenvolveram um estudo no qual um algoritmo de processamento de imagem baseado em rede neural foi proposto para classificação de imagens acústicas por AUVs. Identificaram-se, apesar do sucesso no desenvolvimento do algoritmo, limitações claras, onde apenas objetos simples como cubos, cones e cilindros foram detectados.

Bastian et al. [9] propuseram uma abordagem de visão computacional para detectar corrosão em dutos de águas, óleo e gás. Um banco de dados com mais de cem mil imagens ópticas de dutos, com diferentes níveis de corrosão foi desenvolvido, além de uma rede neural convolucional para classificar as imagens. Adicionalmente, os autores propuseram um método recursivo baseado em regiões para localizar a corrosão em cada imagem. Apesar do resultado de 98,8% de acurácia, o banco de dados deste trabalho foi composto em sua totalidade por imagens de dutos na superfície, e não submarinos.

Neste trabalho, primeiramente serão identificados eventos nas imagens de AUV em escala de cinza já obtidas. Estes eventos serão categorizados utilizando a ferramenta MakeSense, criando uma base de dados. Alguns exemplos de eventos são: cruzamento, anodo, conector, sucata, entrelaçamento, looping. Em seguida, será criada uma rede neural, por meio da teoria de redes neurais convolucionais e da biblioteca Tensorflow do Python. Esta rede será treinada a partir de 70% das imagens do banco de dados e depois testada com os 30% restantes. Os resultados serão analisados e modificações que se fizerem necessárias serão feitas. Na sequência a rede será exportada para um microcontrolador que possa ser embarcado em um AUV (ambos a serem definidos ao longo do projeto). Por fim, será realizada uma inspeção com a rede embarcada no AUV.

#### 6 – ETAPAS (no máximo 2 páginas)

- Revisão da literatura
- Identificar eventos nas imagens de AUV já obtidas
- Categorizar estes eventos
- Criar uma rede neural
- Treinar a rede neural
- Testar a rede neural
- Analisar a acurácia e realizar modificações se necessário
- Exportar a rede neural para um microcontrolador que possa ser embarcado em um AUV
- Realizar uma inspeção com a rede neural embarcada no AUV.

#### 7 – CRONOGRAMA DE TRABALHO (no máximo 1 página)

Dividido por Bimestres (B1, B2...). Total de 12 Bimestres = 24 meses.

	B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11	B12
Identificação dos eventos	█											
Categorização das imagens		█	█									
Criação do Banco de Dados			█									
Modelagem da Rede Neural				█	█	█						
Treinamento da Rede Neural				█	█	█						
Teste da Rede Neural					█	█	█					
Publicação Científica						█	█	█				
Exportação da Rede Neural em um Microcontrolador							█	█	█			
Instalação do Microcontrolador em um AUV									█	█	█	
Testes práticos da aplicação										█	█	█
Publicação Científica / TCC											█	█

#### 8 – DISCIPLINAS DA ESPECIALIZAÇÃO (listar as disciplinas complementares obrigatórias para o

**PRH-ANP que pretende cursar)**

COV253 – Sistemas Submarinos  
 EEN604 - Tecnologia dos Sistemas Oceânicos III  
 COV712 – Sistema Submarinos de Produção II (Pós-Graduação/DENO)  
 COV777 – Construção Naval Eficiente (Pós-Graduação/DENO)  
 COV771 – Mineração de Dados (Pós-Graduação/DENO)  
 EEN641 – Análise Econômica de Projetos e Logística da Produção Oceânica de Petróleo

**9 – REFERÊNCIAS BIBLIOGRÁFICAS**

- [1] KADAMPUR, M. A.; RIYAEE, S. A. Skin cancer detection: Applying a deep learning based model driven architecture in the cloud for classifying dermal cell images. *Informatics in Medicine Unlocked*, v. 18, p. 100282, 20
- [2] FUJII, T.; URA, T. Neural-network-based adaptive control systems for AUVs. *Engineering Applications of Artificial Intelligence*, v. 4, p. 309-318, jan. 1991
- [3] SAYYAADI, H.; URA, T. AUVS Dynamics Modeling Position Control, and Path Planning Using Neural Networks. *IFAC Proceedings Volumes*, v. 34, p. 167-172, jul. 2001
- [4] ALFARO-CID, E. et al. AUV Route Planning using Genetic Algorithms. *IFAC Proceedings Volumes*, v. 36, p. 91-96, abr. 2003
- [5] SHOJAEI, K. Three-dimensional neural network tracking control of a moving target by underactuated autonomous underwater vehicles. *Neural Computing and 17 Applications*, v. 31, p. 509-521, jun. 2017
- [6] WALTHER, D.; EDGINGTON, D. R.; KOCH, C. Detection and tracking of objects in underwater video. *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2004. CVPR 2004*. [S.l.]: IEEE
- [7] GAYA, J. O. et al. Vision-Based Obstacle Avoidance Using Deep Learning. *2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR)*. [S.l.]: IEEE. out. 2016
- [8] KIM, T. W.; YU, S.-C.; YUH, J. Neural network-based underwater image classification for Autonomous Underwater Vehicles. *IFAC Proceedings Volumes*, v. 41, p. 15991-15995, 2008
- [9] BASTIAN, B. T. et al. Visual inspection and characterization of external corrosion in pipelines using deep neural network. *NDT & E International*, v. 107, p. 102134, out. 2019

**10 – OBSERVAÇÕES PERTINENTES (por exemplo recursos financeiros envolvidos etc)**

Local Rio de Janeiro – RJ, Brasil	Data 04/11/2020
--------------------------------------	--------------------