

Identificação e segmentação de *risers* em plataformas *offshore*

Daniel Juchem Regner, Michael W. Batista Machado

INE410121 - Visão Computacional Prof. Aldo Von Wangenheim

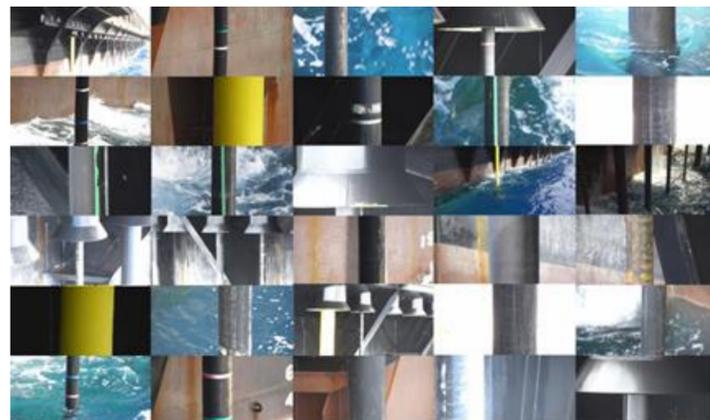
INTRODUÇÃO

Enquanto as tecnologias RPAS (Remotely Piloted Aircraft System) prosperam, alguns estudos estão focados para usar este dispositivo em medições industriais de alta precisão, como por exemplo no auxílio de inspeções em plataformas offshore de produção de petróleo e gás.



OBJETIVOS

O objetivo deste trabalho é mostrar como técnicas de processamento de imagens clássicas e deep learning, baseadas em CNNs, podem contribuir no processo de fotogrametria para realizar inspeções geométricas de risers em plataformas offshore. Utilizou-se como referência e banco de dados para treinamento da rede um dataset real com aproximadamente 997 imagens.



MÉTODOS

Realizou-se a detecção dos risers através de técnicas clássicas de visão computacional e rede neurais convolucionais, conforme a sequência a seguir:

Detecção através de métodos clássicos de visão computacional

- Borramento de Imagem - Gaussian Blur
 - Redução de variações de textura na imagem
- Equalização Histograma - CLAHE
 - Equalização para destacar objetos, em escala de cinza, na imagem
- Erosão com kernel vertical - Erode
 - Utilizado para acentuar objetos verticais
- Detector de bordas de Canny – Canny edge
 - Detecção de borda entre objetos
- Linhas de Hough – HoughLines
 - Geração de linhas na imagem após detecção de borda. Remoção das linhas próximas e com inclinações acima de um limiar especificado.
- Segmentação por COR – inRange
 - Verificação se objeto entre duas linhas está dentro do limiar de cor. Testado em diferentes espaços de cor (RGB, HSV, YCbCr)



Detecção através de redes neurais convolucionais:

- Yolo v5
 - Arquitetura nano,
 - Arquitetura small,
- Detectron2
 - Arquitetura Base-RCNN-FPN

RESULTADOS

As técnicas clássicas não foram capazes de detectar os risers, conforme apresentado nas imagens da esquerda. Por outro lado, as detecções realizadas com as redes neurais foram capazes de detectar os risers de tal forma que o Detectron2 apresentou melhor desempenho, seguido do Yolo v5 nano e Yolo v5 small, os mAP dos processamentos são apresentados na tabela a direita. Entretanto quando apresentado imagens de simulacro de risers a arquitetura Yolo não pode identificar o objeto em questão, diferente da arquitetura Detectron2



Detectron V2

YOLO V5 nano

YOLO V5 small



	mAP @ 0.5:0.95	mAP @ 0.5
Yolo v5 nano	0.982	0.905
Yolo v5 small	0.984	0.92
Detectron2	0.919	0.960

CONCLUSÕES

Os processamentos baseados em técnicas clássicas de visão computacional não apresentaram um resultado satisfatório, possivelmente porque o costado do navio apresenta uma textura muito próxima a do riser dificultando assim a diferenciação dos dois elementos presentes nas imagens.

A partir dos resultados encontrados é possível considerar que em grande parte das imagens a rede neural cumpriu o papel de identificação e segmentação dos risers.

Este é um passo importante, pois permite a utilização desta informação no processo de medição dos componentes, por exemplo executando algum processo que enfatize os objetos de interesse.

Estas informações podem ser utilizadas durante o processo de medição servindo como referência para auxílio na navegação ou até mesmo automatizando as trajetórias de medição.

REFERÊNCIAS

<https://github.com/ultralytics/yolov5>
<https://github.com/facebookresearch/detectron2>
<https://opencv.org/>
<https://www.python.org/>
<https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/>

CONTATOS

daniel.regner@labmetro.ufsc.br
michael.machado@labmetro.ufsc.br
https://codigos.ufsc.br/daniel.regner/computer_vision

