

# 12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



## TÍTULO DO TRABALHO:

Análise da robustez do modelo de visão computacional para o reconhecimento de produtos em um sistema flexível de manufatura aplicado à indústria do petróleo de gás

## AUTORES:

Rafael Serafim Nunes Freire<sup>1\*</sup>, Jefferson Igor Duarte Silva<sup>2</sup>, Adilson José de Oliveira<sup>1</sup>

## INSTITUIÇÃO:

<sup>1</sup>Laboratório de Manufatura, Departamento de Engenharia Mecânica, Universidade Federal do Rio Grande do Norte

<sup>2</sup>Instituto Federal do Rio Grande do Norte

\*Bolsista PRH 44.1, ANP, rafael.serafim.706@ufrn.edu.br

## **ANÁLISE DA ROBUSTEZ DO MODELO DE VISÃO COMPUTACIONAL PARA O RECONHECIMENTO DE PRODUTOS EM UM SISTEMA FLEXÍVEL DE MANUFATURA APLICADO À INDÚSTRIA DO PETRÓLEO E GÁS**

### **Resumo**

Aplicar os conceitos da Indústria 4.0 em processos de manufatura promove flexibilidade e customização de produtos, assim como a redução da interferência humana. Os Sistemas Flexíveis de Manufatura (FMS) são um exemplo direto para aplicação desse conceito, ao integrar máquinas — conectadas por um sistema de transporte e manipulação — a um algoritmo para tomada de decisões. Para um controle computacional adequado, esses sistemas possuem rotinas para verificar parâmetros em tempo real durante o processamento. Em sistemas baseados em imagens ou vídeos, auxiliados por câmeras, é necessário o emprego de um sistema de visão computacional (VC). Quando aplicado aos FMS's, a VC pode ter um algoritmo baseado em uma arquitetura de Rede Neural Convolucional Artificial (CNN) capaz de reconhecer objetos (ou produtos) com o intuito de suportar a tomada de decisões durante as etapas de produção, como a identificação, o transporte e a manipulação. Processos industriais contínuos, como o caso da indústria do petróleo e gás, também se beneficiam desta abordagem devido à troca da participação humana em atividades operacionais por ações de gerenciamento. Para que o sistema seja capaz de reconhecer objetos, é necessário um treinamento específico da CNN. Um dos fatores que influenciam os indicadores de desempenho do modelo é o caminho da informação até chegar ao algoritmo da CNN. Assim como é para o olho humano, a iluminação é um fator importante para o funcionamento adequado das câmeras devido à luz ser uma energia radiante que influencia a qualidade das imagens capturadas por uma câmera. Uma variável que pode medir a quantidade de luz que incide sob uma superfície é a iluminância. Com o intuito de obter um modelo com precisão acima de 90%, este estudo tem como objetivo avaliar a robustez de um modelo de visão computacional existente, que é baseado na arquitetura de CNN YOLOv8, capaz de reconhecer elementos de máquina (porcas, parafusos e arruelas). Dessa forma, foi medida a variação da iluminância sob a região de detecção de objetos, utilizando diferentes configurações de iluminação de duas lâmpadas inteligentes associadas a uma luminária. Após uma análise dos dados obtidos, definiu-se uma faixa de iluminância entre 288 a 2100 lux como mais recomendada para o modelo atual, obtendo precisão superior a 90% e uma evocação de pelo menos 85%.

Palavras-chave: visão computacional, redes neurais convolucionais artificiais, iluminação, lux.

### **Abstract**

The application of Industry 4.0 concepts to the manufacturing processes promotes product flexibility and customization, as well as reducing human interference. Flexible Manufacturing Systems (FMS) are a suitable example of applying this concept by integrating machines — connected by a transportation and handling system — to a decision-making algorithm. For proper computational control, these systems have routines to verify parameters in real time during the processing. In image or video-based systems, aided by cameras, it is necessary to employ a computer vision (CV) system. When applied to an FMS, CV can have an algorithm based on an Artificial Convolutional Neural

Network (CNN) architecture capable of recognizing objects (or products) to support decision-making during production stages, such as identification, transportation, and handling. Continuous industrial processes, such as in the oil and gas industry, can also benefit from this approach by replacing human participation in operational activities to management actions. For the system to recognize objects, specific training of the CNN is necessary. One of the factors influencing the model's performance indicators is the path of information until it reaches the CNN algorithm. As it is for the human eye, lighting is an major factor for the proper functioning of cameras since light is radiant energy that can influence the images quality captured by a camera. A variable that can measure the amount of light incident on a surface is illuminance. To obtain a model with accuracy superior to 90%, this study aims to evaluate the robustness of an existing computer vision model, which is based on YOLOv8 CNN architecture, capable of recognizing machine elements (nuts, bolts, and washers). Thus, the variation of illuminance under the object detection region was measured, using several lighting configurations of two smart lamps associated with a luminaire. An analysis of the data presented that an illuminance range from 288 to 2100 lux was identified as most suitable for the current model, achieving over 90% precision and at least 85% recall.

Keywords: computer vision, artificial convolutional neural networks, lighting, lux.

### Introdução

A implementação dos conceitos da Indústria 4.0 em processos produtivos permite a automação e obtenção de uma taxa de produção flexível. Outro benefício é a customização de produtos ao integrar esses processos com tecnologia da informação, de modo a atender a variabilidade da demanda de produtos pelo mercado. Nesse contexto, os métodos de produção utilizam o conceito de Sistemas Flexíveis de Manufatura (FMS, de Flexible Manufacturing System), os quais consistem em um conjunto de máquinas comumente gerenciadas por comandos numéricos computadorizados (CNC's) e interligadas por um sistema de transporte e manipulação de produtos. Esse sistema é comandado por um computador central (Axelsson, Fröberg e Eriksson, 2019; Weckenborg *et al.*, 2023).

Integrado ao FMS, utiliza-se de transdutores para extração de informações destinadas às tomadas de decisões. Para tarefas visuais, as câmeras são comumente empregadas nessa função. Dessa forma, um subsistema de Visão Computacional (VC) deve ser integrado ao FMS. O subsistema de VC é o responsável pelo processamento das imagens obtidas com o auxílio de câmeras e rotinas computacionais. Essas rotinas podem ser segmentadas em 6 etapas: a) formação do banco de dados de imagens; b) pré-processamento; c) segmentação da imagem; d) extração de informações; e) rotulação; f) tomada de decisão (Romeral, Zancul e Nascimento, 2023).

Associado às referidas rotinas, o uso de Redes Neurais Convolucionais Artificiais (CNN, Artificial Convolutional Neural Network) para as etapas de processamento de imagem é o mais comum. Essa escolha está associada à sua ampla aplicabilidade na área de reconhecimentos de padrões em dados visuais, como a separação de resíduos sólidos, diagnósticos a partir de imagens médicas ou reconhecimento de objetos (Fan *et al.*, 2023). As CNN's são definidas como arquiteturas de processamento de imagem, compostas por diversas camadas, na qual cada uma passa por um processo de convolução a partir de uma imagem na entrada da camada. O processo de convolução aplica um filtro multidimensional na imagem, como o de suavização ou de destaque de contornos, gerando um conjunto de dados esperado (Khan *et al.*, 2018).

Um dos aspectos importantes para a visão considerando o olho humano é a luz. A luz consiste em uma energia radiante cuja reflexão ou emissão sob superfícies podem causar estímulos visuais aos receptores do olho (cones ou bastonetes) e gerar a percepção de imagens (IES, 1947). Um aspecto importante para a percepção é o fluxo luminoso, definido como a taxa de fluxo temporal da luz, ou seja, a quantidade de luz visível emitida por unidade de tempo (indicado em lúmens). Analogamente, propriedades da luz como posição, brilho, temperatura e cor da lâmpada afetam a qualidade das imagens (Hunter, Biver e Fuqua, 2012) e uma maneira de mensurar a fonte luminosa, é pela iluminância, definida como o fluxo luminoso que incide sob determinada área (mensurado em lúmens por metro quadrado, lux) (Simons e Bean, 2001).

A indústria do petróleo e gás aplica a VC em instalações petrolíferas, como o método proposto por Melo, Costa e Costa Filho (2020) que detecta vazamentos de gás natural com uma arquitetura de CNN. O sistema processa imagens digitais para detectar nuvens visíveis de vapores de hidrocarbonetos, ou seja, gás natural sem a utilização de espectro infravermelho.

Batista *et al.* (2024) propôs um modelo que utiliza um sistema de VC baseado na arquitetura YOLOv8 para o reconhecimento de objetos, os quais são elementos de máquina (porcas, parafusos e arruelas), em um protótipo de FMS. Em uma primeira rodada de treinamento, esse sistema teve uma precisão de 89,7% com uma velocidade de processamento de 25 quadros por segundo. O estudo atual tem como objetivo encontrar um método, baseado na variação das condições de iluminação (temperatura, brilho e cor das lâmpadas) sob a região de detecção do objeto, para definir uma faixa de iluminância que proporcione uma melhora dos indicadores de desempenho para o modelo já existente, bem como compreensão das limitações desse modelo. Os conceitos desenvolvidos nesse estudo serão explorados para aplicações na indústria do petróleo e gás, ao se utilizar de CNN's para tarefas como a detecção de falhas mecânicas em equipamentos, classificação de substâncias por cor e/ou densidade, inspeção de tubulações ou monitoramento de instalações.

### Metodologia

Apesar de a precisão encontrada por Batista *et al.* (2024), em uma primeira rodada de treinamento, ser apenas 0,3% menor do que o requerido, o estudo atual fez uma avaliação da robustez do modelo para aumentar sua precisão e entender as limitações do modelo.

O fluxograma da Figura 1 ilustra os subsistemas que compõe o FMS e as etapas desenvolvidas para atingir o objetivo do atual estudo, evidenciando as atividades referentes a avaliação da robustez do modelo atual.




Figura 1. Fluxograma das etapas de desenvolvimento do estudo. a) Protótipo do FMS. b) análise da robustez do modelo.

Na Figura 1a, observa-se que o sistema de VC é apenas um dos sistemas que compõem o protótipo do FMS. Esse sistema de VC deve ser capaz de reconhecer objetos em uma esteira e transmitir essas informações ao algoritmo de controle do FMS, desenvolvido no software LabView 2017, de maneira que o sistema seja capaz de tomar uma decisão para realizar a manipulação do objeto para um local de destino utilizando um manipulador robótico. A Figura 1b descreve o método de avaliação da robustez, que pode ser dividido em quatro etapas: Na etapa 1, é realizada a aquisição de imagens para os testes funcionais; paralelamente, realizou-se a medição dos valores de iluminância (em lux) para cada configuração de iluminação usada. Em seguida, na etapa 2 foi desenvolvido um algoritmo para realizar os testes funcionais do modelo, em que o modelo treinado foi testado para reconhecer os elementos no conjunto de imagens obtidos na etapa 1. Na etapa 3 foi desenvolvido um algoritmo para analisar e interpretar os resultados obtidos na etapa anterior. Por fim, definiu-se uma faixa de iluminância em que o modelo apresentou um desempenho adequado para os indicadores de precisão e evocação, com base nos dados da etapa 3. As Equações 1 e 2 descrevem como esses indicadores de precisão e evocação foram calculados.

$$precisão = \frac{VP}{VP + FP} \quad (1)$$

$$evocação = \frac{VP}{VP + FN} \quad (2)$$

Em que VP é verdadeiro positivo, os casos em que o modelo acertou o objeto a ser reconhecido. FP é Falso Positivo, quando o modelo incorretamente identifica um objeto. FN é Falso Negativo, em que o modelo incorretamente identificados como negativo.

Os materiais utilizados na execução dessa pesquisa foram uma câmera webcam, modelo C922 Logitech®, 1080p e taxa de atualização de 30 fps; acoplada em um suporte em formato de ponte, fabricado em aço e com dimensões máximas 71 x 300 x 630 mm; duas lâmpadas smart color RGB+W com 806 lúmens da marca Lis, associadas a uma luminária de prancheta articulada com suporte para duas lâmpadas. O software Logitech Capture, versão 1.10.110 da Logitech®, foi utilizado para a aquisição de imagens. Um luxímetro digital DT-8809A da CEM Instruments. para medir os valores de iluminância, capaz de coletar dados na faixa de 0 a 400 klux. Para a execução dos testes, utilizou-se um servidor composto por: (a) 2 x CPU Intel(R) Xeon(R) CPU E5-2683 v4; (b) 8 x Tesla V100-SXM2- 16GB; (c) 512 GB RAM DDR4 2400 DIMM (16 x 32GB); a arquitetura utilizada foi a YOLOv8x (Jocher, Chaurasia e Qiu, 2023). O software Visual Studio Code da Microsoft foi utilizado para tratar e organizar os dados obtidos no treinamento. O computador utilizado no processo de análise de dados tinha a seguinte configuração: (a) Processado Intel(R) Core i7 13th 2.10 GHz; (b) Placa de vídeo NVIDIA RTX 3060 12GB; (c) 16GB RAM. Os códigos desenvolvidos nesse estudo estão disponíveis no repositório do Github em Freire (2024a). E o conjunto de dados também está disponível em Freire (2024b). Ambos podem ser utilizados e adaptados pela comunidade científica para aplicações semelhantes na área de visão computacional.

## Resultados e Discussão

As Figuras 3a - 3c apresentam os indicadores de precisão e de evocação em função dos valores de iluminância. Os valores de iluminância, precisão e evocação também estão dispostos na Tabela 1, organizados mediante as configurações luminosas.




Figura 3. Valores de precisão e evocação em função da iluminância. a) Arruelas. b) Parafusos. c) Porcas.

Tabela 1. Valores de iluminância e de precisão para cada configuração luminosa.

| Configuração    | Iluminância [lux] | Arruelas    |             | Parafusos   |             | Porcas      |             |
|-----------------|-------------------|-------------|-------------|-------------|-------------|-------------|-------------|
|                 |                   | p           | e           | p           | e           | p           | e           |
| R               | 68,1              | 0,91        | 0,84        | 0,91        | 0,75        | 0,89        | 0,79        |
| R&B             | 92,4              | 0,88        | 0,72        | 0,77        | 0,49        | 0,68        | 0,40        |
| <b>Ambiente</b> | <b>288,1</b>      | <b>0,98</b> | <b>0,94</b> | <b>0,97</b> | <b>0,91</b> | <b>0,90</b> | <b>0,88</b> |
| <b>50-50</b>    | <b>2013,2</b>     | <b>1,00</b> | <b>0,98</b> | <b>0,95</b> | <b>0,87</b> | <b>0,95</b> | <b>0,92</b> |
| <b>50-100</b>   | <b>2099,2</b>     | <b>0,98</b> | <b>0,92</b> | <b>0,98</b> | <b>0,91</b> | <b>0,94</b> | <b>0,85</b> |
| 100-0           | 2830              | 0,97        | 0,76        | 0,93        | 0,75        | 0,90        | 0,64        |
| 100-100         | 3314              | 0,77        | 0,66        | 0,96        | 0,81        | 0,93        | 0,72        |
| <b>100-50</b>   | <b>3324,6</b>     | <b>1,00</b> | <b>0,94</b> | <b>0,99</b> | <b>0,89</b> | <b>0,99</b> | <b>0,89</b> |

Nota: “p” e “e” significam, respectivamente, precisão e evocação.

As configurações expostas na primeira coluna da Tabela 1 possuem códigos com o seguinte significado: Configuração x-y, onde ‘x’ representa o brilho da lâmpada (em porcentagem) e ‘y’ representa a temperatura da lâmpada (em porcentagem). A Temperatura ‘y’ também impacta no tom da cor, pois temperaturas menores possuem cores quentes, com um tom amarelado (0%); cores neutras possuem um tom branco (50%); e altas temperaturas possuem cores frias, com tons azulados (100%). Essas temperaturas costumam variar de 3000 a 6500 Kelvin (Lumienergy, 2020). O R significa que as lâmpadas possuem coloração vermelha (Red), enquanto R&B significa que uma das lâmpadas possuem cor vermelha enquanto a outra está com a cor azul (Red & Blue).

Como é possível observar nas Figuras 3a – 3c e na Tabela 1, a precisão do modelo não teve um comportamento linear (crescente ou decrescente) conforme os valores de iluminância aumentaram, isso está conforme mencionado por Hunter, Biver e Fuqua (2012), de que vários aspectos da iluminação são relevantes para as imagens, como brilho, posição, temperatura e cor da fonte luminosa. Além disso, é possível notar que o modelo se comporta melhor em tons brancos (configurações 50-50 e 100-50), no qual se obteve precisões entre 94 a 100% em todos os tipos de elementos. Por outro lado, se comporta de maneira inconsistente em tons mais azuis (configurações R&B e 100-100), tendo os piores valores de precisão e evocação para alguns elementos.

## Conclusões

O atual estudo avalia a robustez de um modelo de visão computacional baseado na arquitetura de CNN YOLOv8x. Mediante os resultados obtidos, pode-se concluir que:

- Uma margem de iluminância de 288 a 2100 lux para o sistema de visão computacional do protótipo do FMS proporcionou precisão média para a análise de porcas, parafusos e arruelas de 96% com uma evocação média de 91% com a utilização da configuração 100-50 (2013,2 lux);
- Os tons neutros (temperatura das lâmpadas em 50%) favoreceram os indicadores de desempenho em até de 3 a 10%, portanto, é o mais indicado para o estudo em questão.
- Apesar de não estar na faixa do item a), a configuração 100-50 (3324,6 lux) também apresentou resultados adequados, obtendo de 99 a 100% de precisão e para porcas, arruelas e parafusos com uma evocação de 90%.

## **Agradecimentos**

Os autores agradecem ao Programa de Formação de Recursos Humanos para o Setor de Petróleo, Gás Natural e Biocombustíveis (PRH-ANP) 44.1 pelo apoio no desenvolvimento desta pesquisa.

## **Referências Bibliográficas**

AXELSSON, J.; FRÖBERG, J.; ERIKSSON, P. Architecting systems of systems and their constituents: A case study applying Industry 4.0 in the construction domain. **Systems engineering**, v. 22, n. 6, p. 455–470, 2019.

BATISTA, L. *et al.* Desenvolvimento de um protótipo de sistema flexível de manufatura baseado em visão computacional. *In* anais do Congresso Nacional de Engenharia Mecânica (CONEM), 12, 2024, Natal. Anais [...]. Rio de Janeiro: ABCM, 2024.

FAN, M. *et al.* A lightweight multiscale convolutional neural network for garbage sorting. **Systems and Soft Computing**, v. 5, n. 200059, p. 200059, 2023.

Freire, R. S. N. **Visão Computacional para um FMS**. 2024a. Disponível em: [https://github.com/Serafim-R/computer\\_vision\\_cnn\\_for\\_fms](https://github.com/Serafim-R/computer_vision_cnn_for_fms). Acesso em: 04/07/2024.

Freire, R. S. N. Projects: **Labman\_prh\_ic**. 2024b. Disponível em: [https://app.roboflow.com/universidadefederaldoriograndedonortheasternfrn/labman\\_prh\\_i/](https://app.roboflow.com/universidadefederaldoriograndedonortheasternfrn/labman_prh_i/). Acesso em: 04/07/2024.

HUNTER, F.; BIVER, S.; FUQUA, P. **Light Science and Magic**. 4. ed. Boston, MA, USA: Focal Press, 2012. ISBN 978-0-240-81225-0.

Illuminating Engineering Society. **IES lighting handbook: the standard lighting guide**. Baltimore, Maryland, USA: THE WAVERLY PRESS, 1947.

JOCHER, G.; CHAURASIA A.; QIU, J. **Ultralytics YOLOv8**. 2023. Disponível em: <https://github.com/ultralytics/ultralytics>. Acesso em 05/07/2024.

Lumienergy. **Temperatura da cor da luz: o guia definitivo**. 2020. Disponível em: <https://blog.lumienergy.com.br/temperatura-da-cor-da-luz-o-guia-definitivo/>. Acesso em: 05/07/2024.

MELO, R. O.; COSTA, M. G. F.; COSTA FILHO, C. F. F. Applying Convolutional Neural Networks to Detect Natural Gas Leaks in Wellhead Images. **IEEE Access**, v. 8, p. 191775-191784, 2020, DOI <https://doi.org/10.1109/ACCESS.2020.3031683>. Acesso em 04/07/2024.

ROMERAL, P. A. A. F.; ZANCUL, E. S.; NASCIMENTO, P. T. S. Visão computacional na indústria: tendências e exemplos práticos. *In*: Anais do Encontro Nacional de Engenharia de Produção (ENEGEP), 43. 2023, Fortaleza. Anais [...]. Rio de Janeiro: ABEPRO, 2023. p. 1-15. DOI: [https://doi.org/10.14488/enegep2023\\_tn\\_st\\_404\\_1990\\_45733](https://doi.org/10.14488/enegep2023_tn_st_404_1990_45733). Acesso em: 04 julho 2024.

WECKENBORG, C. *et al.* Flexibility in manufacturing system design: A review of recent approaches from Operations Research. **European journal of operational research**, v. 315, n. 2, 1 junho 2024. p. 413-441. DOI: <https://doi.org/10.1016/j.ejor.2023.08.050>. Acesso em: 04 julho 2024.