



Automação do Teste de Van de Castele via Aprendizado Profundo: Viabilidade e Análise da Amostragem Instantânea

Automation of the Van de Castele Test via Deep Learning: Feasibility and Analysis of Instantaneous Sampling

Salomão Soares ¹, Regiane Dalazoana ², Mariana Eiko Borba Inoue ³, Everton Gomes dos Santos ⁴ e Luiz Fernando Reinheimer ⁵

¹ Universidade Federal do Paraná, Curitiba, Brasil. E-mail: salomao.soares@ufpr.br.

ORCID: <https://orcid.org/0000-0003-4826-776X>

² Universidade Federal do Paraná, Curitiba, Brasil. E-mail: regiane@ufpr.br.

ORCID: <https://orcid.org/0000-0001-5468-0679>

³ Universidade Federal do Paraná, Curitiba, Brasil. E-mail: mariana.inoue@ufpr.br.

ORCID: <https://orcid.org/0000-0002-2008-3769>

⁴ Instituto Brasileiro de Geografia e Estatística, Rio de Janeiro, Brasil. E-mail: everton.santos@ibge.gov.br.

ORCID: <https://orcid.org/0000-0002-8730-7755>

⁵ Instituto Brasileiro de Geografia e Estatística, Florianópolis, Brasil. E-mail: luiz.reinheimer@ibge.gov.br.

ORCID: <https://orcid.org/0009-0005-6858-6604>

Recebido: 02.2026 | Aceito: 06.2026

Resumo: O Teste de Van de Castele é uma etapa importante na análise da qualidade das observações das estações maregráficas, mas sua execução manual é laboriosa. Para automatizar esse processo, esta pesquisa avaliou o uso de um modelo de aprendizado profundo baseado em YOLO, aplicado a imagens da régua de marés da estação maregráfica de Arraial do Cabo, capturadas por câmeras digitais de baixo custo. O estudo também analisou os limites da inferência instantânea, caracterizada pela medição direta de imagens, sem os filtros de média temporal comuns em sensores eletrônicos. Na detecção da régua de marés, o modelo apresentou excelente desempenho em vários cenários, com mAP50 de 0,995 e mAP50-95 variando de 0,844 a 0,913. A validação metrológica comparou cinco experimentos, tendo como referência o método convencional. Em relação à precisão, enquanto os sensores Radar e Encoder apresentaram desvios padrão (DP) de 0,02 m quando comparados aos registros da régua de marés feitos por um observador, o modelo de visão computacional convergiu para um DP de 0,03 m ao longo dos experimentos. Essa variabilidade ligeiramente maior, juntamente com um viés sistemático identificado, é atribuída à captura instantânea da superfície do mar, que registra ruídos de alta frequência (ondas) que são filtrados pela integração temporal dos sensores de nível e pelo observador. Portanto, os resultados demonstram que, considerando a natureza instantânea da captura de imagem, a técnica é robusta e viável para automatizar o Teste de Van de Castele.

Palavras-chave: Teste de Van de Castele. Aprendizado Profundo. Marégrafo. Régua de Marés.

Abstract: The Van de Castele Test is an important step in analyzing the quality of observations from tidal stations, but its manual execution is laborious. To automate this process, this research evaluated the use of a deep learning model based on YOLO, applied to images of the tide staff of the Arraial do Cabo tide-chart station, captured by low-cost digital cameras. The study also analyzed the limits of instantaneous inference, characterized by direct image measurement without the common time-mean filters in electronic sensors. In tide staff detection, the model showed excellent performance across various scenarios, with mAP50 of 0.995 and mAP50-95 ranging from 0.844 to 0.913. The metrological validation compared five experiments, using the conventional method as a reference. Regarding accuracy, while the Radar and Encoder sensors showed standard deviations (SD) of 0.02 m when compared to tide staff readings taken by an observer, the computer vision model converged to a SD of 0.03 m throughout the experiments. This slightly higher variability, together with an identified systematic bias, is attributed to the instantaneous capture of the sea surface, which records high-frequency noises (waves) that are filtered by the temporal integration of level sensors and the observer. Therefore, the results demonstrate that, given the instantaneous nature of image capture, the technique is robust and feasible for automating the Van de Castele Test.

Keywords: Van de Castele Test. Deep Learning. Tide Gauge. Tide Staff.

1 INTRODUÇÃO

Desde a definição clássica de Gauss e Listing, a determinação das variações do nível do mar, reduzidas pela média em um determinado período e local, tornou-se ponto de partida para as redes de controle vertical dos países. Entretanto, essas superfícies de referência locais apenas se aproximam do geoide ou do quasigeoide, devido ao efeito da topografia da superfície do mar e das anomalias locais do nível do mar, com desvios que podem atingir ± 2 m em relação ao geoide global (Gemaël, 2019; Torge & Müller, 2012; Sánchez & Sideris, 2017).

Apesar da concepção atual entender que o nível médio do mar não é uma superfície em equilíbrio no campo de gravidade da Terra (Torge & Müller, 2012), o seu monitoramento permanente continua desempenhando um papel importante para uma vasta gama de domínios científicos e operacionais, tais como aplicações em trabalhos hidrográficos tradicionais, previsões de marés, tendências de longo prazo do nível do mar, calibração da Altimetria por Satélites (ALTSAT), entre outros (CHM, 2025; IOC, 2024; Birol et al., 2025).

De acordo com a Comissão Oceanográfica Intergovernamental (IOC, 2024), a variabilidade do nível do mar na maioria dos locais, com amplitudes tipicamente decimétricas em escala decadal, não permite a detecção de tendências seculares, mesmo com sensores mais precisos, sem um registro de pelo menos 50 anos. Portanto, a ênfase de programas como o Sistema Global de Observação do Nível do Mar (*Global Sea Level Observing System* – GLOSS) tem sido colocada na capacidade de realizar medições de longo prazo com precisão de 1 cm (UNESCO, 2002). Este requisito rigoroso reflete a necessidade de dados altamente precisos e confiáveis, essenciais às crescentes demandas científicas e operacionais contemporâneas.

Nesse contexto de dados precisos, o Teste de Van de Casteele (TVC), concebido para o controle de qualidade e a caracterização de erros em mareógrafos analógicos, ainda é utilizado na era dos mareógrafos digitais (Miguez et al., 2008), mantendo-se como etapa fundamental na implantação e no acompanhamento de estações mareográficas. Ele se caracteriza por leituras sucessivas e simultâneas do nível d'água no sensor mareográfico e em outro equipamento de referência independente ao longo de um ciclo completo de maré (13 h). As diferenças entre as leituras dos dois sensores devem permanecer constantes; porém, isso só ocorre com um mareógrafo perfeito. O TVC auxilia na determinação da precisão do mareógrafo por meio da construção de um diagrama cuja forma permite identificar diferentes tipos de falhas. Para mais detalhes, consulte a UNESCO (1985). Na impossibilidade de uma coleta completa, observações realizadas em curto período de tempo, em torno da maré alta ou baixa, preferencialmente nas marés de sizígia, também permitem análises adequadas (UNESCO, 2016). Além disso, através do TVC é possível determinar a relação entre os diferentes referenciais instrumentais (zeros da régua e dos sensores), o que auxilia no processo de correlação dos níveis de referência (Dalazoana et al., 2005).

A sua aplicação regular é recomendada, especialmente após qualquer atualização ou modernização dos sensores de nível, o que ressalta sua relevância duradoura como ferramenta fundamental de controle de qualidade. Entretanto, o TVC é, em essência, um procedimento manual realizado in situ, o que o torna uma etapa laboriosa e de longa duração (Miguez et al., 2008; SONEL, 2019).

Há diversas possibilidades de equipamentos eletrônicos que podem servir como referência independente, desde outro sensor mareográfico, passando por sondas elétricas, estação total com o método trigonométrico, etc (Miguez et al., 2008; SONEL, 2019; Silveira, 2023). O Instituto Brasileiro de Geografia e Estatística (IBGE) utiliza a régua de marés no TVC, pois permite a observação do nível d'água de forma independente de qualquer fonte de energia, de sistemas de registro e de mecanismos de filtragem, constituindo, assim, o principal elemento de aferição das observações dos sensores mareográficos (IBGE, 2010).

Embora o TVC seja fundamental para a aferição de sensores de nível, sua aplicação convencional pode estar se aproximando de seus limites, já que à medida que as redes mareográficas se modernizam e se expandem globalmente, depender de processos manuais torna-se um fator limitante para um controle de qualidade eficiente e generalizado. Nesse sentido, e de acordo com LeCun, Bengio e Hinton (2015), a visão computacional moderna evoluiu significativamente com o aprendizado profundo, permitindo que redes neurais convolucionais aprendessem automaticamente representações hierárquicas diretamente a partir dos dados visuais. Como exemplo, cita-se que Lima (2019) utilizou régua plástica para identificar o avanço ou recuo de rachaduras em imóveis, obtendo precisão de 75,65%; Freitas (2022) buscou identificar defeitos em

pavimentos rodoviários, obtendo precisões de 99,89% e 95,91% para buracos e remendos, respectivamente.

Contudo, a aplicação da visão computacional à leitura de réguas de marés físicas ainda é pouco explorada na literatura. Esta pesquisa inova ao integrar hardware de baixo custo e uma arquitetura de detecção de estágio único para replicar a percepção visual humana no TVC. Este artigo constitui uma versão estendida de Soares et al. (2025), apresentada no I CIRF & VIII SIMGEO – Regularização Fundiária Plena & Geotecnologias, e tem como objetivo analisar o potencial do aprendizado profundo para a detecção do alvo, auxiliando o algoritmo de visão computacional na determinação de valores métricos do nível d'água a partir de imagens capturadas por câmeras digitais. Parte-se da hipótese de que a automação desse fluxo de trabalho tradicional pode tornar o TVC menos oneroso, permitindo sua execução com maior frequência e, assim, contribuindo para a redução de identificações tardias de falhas instrumentais.

No presente trabalho, são utilizadas imagens da régua de marés da estação maregráfica de Arraial do Cabo-RJ, capturadas por câmeras digitais integradas a módulos ESP32-CAM, em intervalos de 2 e 5 minutos, para avaliar quatro instâncias de treinamento baseadas na arquitetura YOLOv8 (*You Only Look Once*). A fase de inferência consiste em detectar a régua de marés com YOLOv8, gerando caixas delimitadoras (*bounding boxes*) que servem de base para a extração de atributos métricos. Um algoritmo de pós-processamento converte as coordenadas dos pixels da borda inferior da caixa delimitadora em valores métricos (em metros) por meio de uma função de transferência polinomial de segundo grau. Ao todo, foram conduzidos cinco experimentos para analisar o desempenho da inferência baseada em imagens instantâneas. Estas medições são processadas isoladamente, imagem por imagem, sem qualquer mecanismo de filtragem temporal ou de suavização, para que os limites da técnica ótica possam ser rigorosamente testados em relação à dinâmica natural do nível do mar.

2 METODOLOGIA


Nesta seção, apresentam-se a localização e a caracterização da estação maregráfica, os materiais utilizados na obtenção das imagens, a preparação do conjunto de dados e os fundamentos do aprendizado profundo com YOLOv8. O código foi desenvolvido em Python para uso direto no Google Colab (GOOGLE, 2026), utilizando o acelerador de hardware *Tensor Processing Unit* (TPU v2-8) durante a etapa de treinamento. A adoção desta infraestrutura visou otimizar o processamento computacional e reduzir o tempo de convergência dos quatro modelos treinados. Ressalta-se que, após esta etapa, os pesos resultantes dispensam um acelerador de hardware dedicado e podem ser empregados em Unidades Centrais de Processamento (CPU) convencionais para realizar as inferências. Tal característica confere portabilidade ao método, possibilitando sua aplicação em ambientes computacionais de menor capacidade de processamento ou em dispositivos de borda.

2.1 Localização e caracterização da estação maregráfica de Arraial do Cabo - RJ

A estação maregráfica utilizada nessa pesquisa faz parte da Rede Maregráfica Permanente para Geodésia (RMPG) e fica localizada no município de Arraial do Cabo, no Estado do Rio de Janeiro (22°58'21"S 42°00'48"O, SIRGAS2000), sigla EMARC, mais especificamente, nas dependências do Porto do Forno, administrado pela Companhia Municipal de Administração Portuária (COMAP) e operada pelo IBGE desde 2017. A Figura 1 apresenta a localização da EMARC.


O sistema é composto por dois sensores de nível: um sensor Radar, que realiza medições sem contato com a água por meio de ondas eletromagnéticas, e um codificador de eixo eletrônico (Encoder), que opera segundo o princípio mecânico de contrapeso e boia. Além disso, possui sensores meteorológicos auxiliares e uma régua de marés (IBGE, 2021). A Figura 2 mostra os sensores e as estruturas que compõem a estação.

Figura 1 – Localização da estação maregráfica de Arraial do Cabo-RJ da RMPG.



Elaboração: Os Autores (2026).

Figura 2 – a) Visão geral dos sensores disponíveis na estação maregráfica. b) Localização da régua de marés fixada na lateral do cais. c) Sensor Radar. d) Sensor Encoder.




Elaboração: Os Autores (2026).

2.2 Coleta de dados

Para a preparação do conjunto de dados, entre os dias 26 e 27 de março de 2025, durante uma inspeção preventiva, foram instaladas duas unidades de captura independentes. Cada unidade consistiu em um conjunto composto por um módulo microcontrolador ESP32-CAM, uma lente de câmera integrada e um cartão de memória microSD de 32 GB. Estes sistemas foram acondicionados em caixas herméticas e alimentados por um sistema fotovoltaico off-grid, composto por um painel solar de 60 W, um controlador de carga solar de 30 A para sistemas de 12 V e duas baterias estacionárias de 12 V e 7 Ah conectadas em paralelo. Essa configuração garantiu autonomia energética e estabilidade operacional durante toda a campanha de monitoramento. As unidades capturaram imagens da régua de marés em intervalos de 2 e 5 minutos, respectivamente. A Figura 3 apresenta detalhes da instalação. O software de automação da captura foi desenvolvido especificamente para este projeto e carregado no microcontrolador; nesta etapa da pesquisa, a interface Wi-Fi do módulo não foi utilizada para a transmissão de dados, priorizando-se o armazenamento local no cartão microSD. No dia 27, durante a maré de sizígia, o TVC também foi conduzido em seu molde convencional, com o observador realizando leituras do nível d'água na régua de marés a cada 15 minutos no intervalo das 06h00 às 19h00.

Figura 3 – a) Câmeras ESP32-CAM. b) Detalhe da instalação das câmeras c) Local de instalação das câmeras e do painel solar. d) Visão panorâmica do esquema de captura de imagens com destaque em vermelho.




Elaboração: Os autores (2026).

2.3 Preparação do conjunto de dados

As imagens foram submetidas à inspeção para verificação da qualidade, sendo descartados os quadros com obstruções severas ou falhas de iluminação. Em seguida, foram carregadas no aplicativo web de código aberto Make Sense (Skalski, 2022) para a determinação manual das caixas delimitadoras da régua de marés, visando à montagem dos conjuntos de dados de treinamento e de validação. Nessa etapa do processo, o objetivo foi garantir o máximo rigor possível na determinação das partes superior e inferior da caixa delimitadora. Condição necessária para evitar falsos positivos na fase de treinamento, pois a água límpida da região deixava transparecer as partes iniciais submersas, o que poderia levar a interpretações incorretas.

Além disso, as capturas de imagem foram realizadas em diferentes condições de luminosidade, o que acrescentou complexidade ao processo. Segundo Del Rosso et al. (2021), um conjunto de dados de treinamento deve ser representativo, abrangendo todos os recursos e fenômenos a serem identificados, mapeados ou monitorados. A Figura 4 apresenta três amostras de imagens obtidas em diferentes níveis de luminosidade.

Figura 4 – Captura de imagem da régua de marés em diferentes momentos.



Elaboração: Os autores (2026).

Em seguida, as imagens foram divididas em 3 conjuntos: treinamento, validação e teste. Para o conjunto de treinamento, houve um cuidado adicional na separação das imagens que representassem o maior universo possível de possibilidades, ou seja, maior variabilidade de momentos de alta e baixa luminosidade e de marés altas e baixas, a fim de formar um conhecimento claro sobre a régua de marés como elemento-alvo no processo de aprendizado. Para os conjuntos de teste e de validação, os dados foram divididos aleatoriamente, com a maior parte alocada ao conjunto de teste. Essa divisão priorizou um conjunto de teste

robusto para garantir a avaliação externa da capacidade de generalização do modelo. A organização detalhada dos conjuntos está descrita na Tabela 1

Tabela 1 – Quantidade de imagens digitais utilizadas em cada etapa do processo de detecção.


Conjunto	Quantitativo	Percentual (%)
Treinamento	72	30,2
Validação	41	17,2
Teste	125	52,6
Total	238	100

Fonte: Adaptado de Soares et al. (2025).

2.4 Determinação da função de conversão de valores

Ainda como preparação dos dados, para fins de comparação com os resultados do aprendizado profundo, foram extraídos valores métricos do nível d'água na régua de marés. A extração desses valores em gabinete consistiu na leitura visual detalhada das imagens por um especialista, servindo como "verdade de referência" para validar a precisão do algoritmo. O objetivo foi garantir a equivalência das condições de observação, visto que, no método convencional, o observador determina um valor médio a partir de medições realizadas ao longo de um intervalo temporal, período em que o nível do mar varia continuamente. A Figura 5 apresenta a representação de uma imagem digital e a relação pixel/metro na régua de marés, na qual, por exemplo, o nível de 2,20 m corresponde ao pixel x, y (490, 393) na imagem digital.

Figura 5 – a) Representação de imagem digital; b) Determinação das coordenadas do pixel na régua de marés.



a) Fonte: Adaptado de Jähne (2005); b) Elaboração: Os autores (2026).

O método de identificação através de caixas delimitadoras facilita, no caso específico da régua de marés, o uso das marcas inferiores da imagem, desde que as capturas estejam rigorosamente na vertical, como no caso analisado. Na instalação da câmera digital, os valores do ângulo e da distância eram desconhecidos. Assim, partindo do princípio de que a régua de marés e a câmera estão fixas, buscou-se determinar a função que melhor representasse as constantes da régua nas imagens. A coordenada horizontal (x) foi negligenciada, uma vez que a variável de interesse para o ciclo de maré é estritamente vertical. Em todas as imagens do treinamento, foram extraídos os valores em pixel dos correspondentes métricos na régua de marés, determinando-se a média dos valores ($\bar{y}$), conforme apresentado na Tabela 2.

A análise da posição dos valores evidencia a natureza não linear da relação entre pixel e metro. Além disso, era necessário determinar uma função com capacidade de extrapolação, visto que os níveis d'água poderiam, eventualmente, situar-se abaixo do limite inferior calibrado. Nesta pesquisa, utilizou-se uma função polinomial de 2º grau para representar o conjunto de dados, conforme Eq. (1):

$$f(x) = ax^2 + bx + c \quad (1)$$

na qual a, b e c são os coeficientes (constantes) e x representa a coordenada vertical do pixel da borda inferior


da caixa delimitadora detectada pelo modelo para cada imagem. A Tabela 2 apresenta a relação entre o valor métrico na régua de marés e o respectivo pixel na imagem, e a Figura 6 apresenta a função de conversão resultante desses valores.

Tabela 2 – Relação de escala entre a régua de marés e as imagens da câmera 1.

Régua de marés (m)	$\bar{y}$ (pxl)
2,90	145,38
2,50	298,72
2,20	390,43
1,70	510,94

Fonte: Soares et al. (2025).

Figura 6 – Determinação da função de conversão de pixels para metros nas imagens da câmera 1.



Fonte: Adaptado de Soares et al. (2025).

Para tornar claro o fluxo de processamento e ilustrar como a detecção algorítmica se converte em uma grandeza física, apresenta-se, a seguir, um exemplo numérico da aplicação da função de transferência.

A inferência da arquitetura YOLOv8n fornece como saída a localização do objeto no formato de um vetor de coordenadas $[x_1, y_1, x_2, y_2]$ em pixels. A variável de interesse para esta pesquisa é y_2 , que corresponde à borda inferior da caixa delimitadora, posicionada estritamente na interface entre a régua de marés e a superfície d'água. Tomando como exemplo uma imagem cujo modelo detectou o alvo com a coordenada vertical inferior $y_2 = 401$ pixels, este valor é isolado e aplicado como a variável independente x na Eq. (1), utilizando os coeficientes determinados pela função de conversão do pixel na imagem em valor métrico da câmera 1, conforme Eq. (2) e Eq. (3):

$$y = (-3,327 \times 10^{-6}) \cdot (401)^2 + (-0,00109) \cdot (401) + 3,1279 \quad (2)$$

$$y \approx 2,16 \text{ m} \quad (3)$$

Resolvendo as etapas do polinômio de segundo grau, o resultado do pós-processamento indica que a coordenada de 401 pixels na imagem digital corresponde a um nível d'água de 2,16 m na escala física da régua de marés. Esse valor estimado por inferência computacional é, em seguida, confrontado diretamente com a leitura do observador e com os registros dos sensores físicos (Radar e Encoder) no TVC.

2.5 Aprendizado profundo com YOLO

O aprendizado profundo tornou-se a tecnologia mais discutida atualmente devido aos resultados obtidos nas áreas de classificação de imagens, detecção de objetos e processamento de linguagem (Srivastava et al. 2020). Nesta pesquisa, a detecção da régua de marés desempenha um papel fundamental e pode ser realizada por dois tipos de detectores: de estágio único e de dois estágios.

Os detectores de objetos de dois estágios identificam primeiro as regiões de interesse e, em seguida,

classificam os objetos nessas regiões. Exemplos populares incluem RCNN (*Region-based Convolutional Neural Network*). Por outro lado, detectores de estágio único constroem caixas delimitadoras e classificam objetos simultaneamente usando uma única rede neural de alimentação direta. YOLO e SSD (*Single Shot MultiBox Detector*) são exemplos consolidados desta categoria (Taye, 2023; Zeng & Zhong, 2024).

Nesta pesquisa, adotou-se o YOLOv8 na variante nano (n) (ULTRALYTICS, 2023). Para o desenvolvimento dos modelos, utilizou-se a técnica de Aprendizado por Transferência (*Transfer Learning*), iniciando-se o treinamento a partir dos pesos pré-treinados do conjunto de dados COCO (Lin et al., 2014). Esta abordagem permite que a rede aproveite características visuais básicas já aprendidas (como bordas, formas e texturas), acelerando a convergência para o objeto específico desta pesquisa: a régua de marés. De acordo com Terven et al. (2023), a arquitetura YOLO se destaca por seu notável equilíbrio entre velocidade e precisão, permitindo a identificação rápida e confiável de objetos em imagens.

Embora o treinamento tenha sido realizado em ambiente de nuvem (Google Colab com acelerador de hardware TPU v2-8) para otimizar o tempo de processamento, a escolha da variante nano justifica-se pela portabilidade. O objetivo é garantir que o modelo resultante possa ser implementado futuramente em dispositivos de borda com recursos computacionais limitados, mantendo baixo consumo de memória e alta velocidade de resposta em tempo real. Os principais hiperparâmetros configurados incluíram o redimensionamento das imagens para 768 x 1024 pixels e a execução de 50 ou 100 épocas, conforme o cenário experimental.

2.5.1 MATRIZ DE CONFUSÃO

Uma matriz de confusão compara o rótulo de classe real com o previsto, usando as imagens de teste. Trata-se de uma tabela que apresenta os resultados de um modelo de classificação, conforme se observa na Tabela 3.

Tabela 3 – Matriz de confusão.

Predito	Real Positivo	Real Negativo
Positivo	TP	FP
Negativo	FN	TN

Fonte: Soares et al. (2025).

Onde cada célula contém os valores de verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN), sendo frequentemente utilizada para avaliar o desempenho de modelos de detecção e de classificação.

2.5.2 PARÂMETRO DE ERRO DE TREINAMENTO E VALIDAÇÃO

No processo de utilização da arquitetura YOLOv8, monitoram-se diferentes componentes de perda (*loss*) para avaliar o desempenho do aprendizado. A perda da caixa delimitadora (*box loss*) mede o erro na predição e na localização das caixas em relação aos rótulos reais (*ground truth*). A perda de classificação (*cls loss*) representa o erro na identificação da classe do objeto. Já a perda de distribuição de regressão (*dfl loss*) refina a geometria da caixa ao modelar a incerteza da posição com maior precisão. Essas métricas são calculadas tanto para os dados de treino (*train*) quanto para os de validação (*val*), permitindo diagnosticar o estado de ajuste do modelo.

Um subajuste (*underfitting*) ocorre quando o modelo é muito simples ou o treinamento é insuficiente, resultando em erros elevados em ambos os conjuntos (treino e validação). Já o sobreajuste (*overfitting*) caracteriza-se por uma redução contínua da perda de treinamento, enquanto a perda de validação se estabiliza ou aumenta. Indica que o modelo "memorizou" os dados de treino, mas falha ao lidar com dados inéditos. Para um ajuste ideal, é necessário que haja convergência entre as curvas de perda de treino e de validação, decrescentes e suaves, que se estabilizem em valores baixos e similares (Mucci, 2024). A semelhança de comportamento entre os dois gráficos é o principal indicativo de que o modelo generalizou adequadamente os recursos visuais da régua de marés, o que garante a robustez das detecções.

2.5.3 MÉTRICAS DE AVALIAÇÃO

Em tarefas de detecção de objetos, as métricas a seguir são comumente empregadas para avaliar a relação entre as previsões do modelo e os rótulos reais, fornecendo uma base para a avaliação de desempenho e a otimização de algoritmos (Terven et al., 2023; Zeng & Zhong, 2024; ULTRALYTICS, 2023).

A interseção sobre a União (*Intersection over Union – IoU*) é uma métrica fundamental na detecção de objetos, que quantifica a sobreposição entre as caixas delimitadoras previstas (B_p) e as reais (B_{gt}). Ela desempenha um papel fundamental na avaliação da precisão da detecção. Matematicamente, IoU pode ser definida conforme Eq. (4):

$$IoU = \frac{Area(B_p \cap B_{gt})}{Area(B_p \cup B_{gt})} = \frac{\text{Área da Interseção}}{\text{Área da União}} \quad (4)$$

Precisão (*Precision*) quantifica a proporção de detecções de verdadeiros positivos (TP) em relação ao número total de detecções (TP + FP), ou seja, mede quantas das detecções positivas realmente são corretas, conforme definido pela Eq. (5):

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Sensibilidade (*Recall*) quantifica a capacidade do modelo de identificar corretamente todos os objetos alvos presentes nas imagens, conforme definido pela Eq. (6):

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

A Média das Precisões Médias (*mean Average Precision – mAP*) é uma métrica global que sintetiza os índices de precisão e de sensibilidade em múltiplos limiares de confiança. O seu cálculo fundamenta-se na Precisão Média (*Average Precision – AP*), que corresponde, matematicamente, à área sob a curva de precisão-sensibilidade de cada categoria, isoladamente, conforme definido pela Eq. (7):

$$AP = \sum_{k=1}^m (Recall_k - Recall_{k-1}) \cdot Precision_k \quad (7)$$

Na qual m representa o número total de limiares de confiança avaliados ao longo da curva, enquanto $Precision_k$ e $Recall_k$ correspondem aos valores de precisão e sensibilidade obtidos no k -ésimo limiar. Na Eq. (8), o parâmetro n denota o número total de classes avaliadas no conjunto de dados, assumindo o valor de $n = 1$ nesta pesquisa por se tratar estritamente de um alvo único (a régua de marés):

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (8)$$

A métrica mAP50 indica a precisão média calculada com um limiar de Intersecção sobre a União (IoU) de 0,5, ou seja, a detecção é considerada um verdadeiro positivo quando a sobreposição entre a caixa delimitadora prevista e a real é de, no mínimo, 50%. Já o mAP50-95 é um parâmetro mais rigoroso, que representa a média do mAP calculada em intervalos de IoU de 0,5 a 0,95, com incrementos de 0,05.

2.6 Avaliação estatística

A determinação das estatísticas básicas de média, erro padrão, mediana, desvio padrão, mínimo e máximo, bem como do intervalo de confiança de 95%, foi utilizada para apresentar o resumo dos resultados

obtidos nas imagens em gabinete e os obtidos automaticamente pelo aprendizado profundo. Para avaliar se a diferença entre as médias observadas das duas amostras foi estatisticamente significativa, realizou-se o teste t de Student para amostras independentes. Para isso, calculou-se o erro padrão da diferença entre as duas médias (EP_d), conforme definido pela Eq. (9):

$$EP_d = \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}} \quad (9)$$

em que EP_d é o erro padrão da diferença entre as duas médias, S_1^2 e S_2^2 são as variâncias das amostras e n_1 e n_2 são os tamanhos das amostras, representados pelo quantitativo de imagens analisadas na fase de teste.

Em seguida, determinou-se o teste t de Student para amostras independentes utilizando a Eq. (10):

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{EP_d} \quad (10)$$

na qual t é a estatística t de Student, $\bar{x}_1$ e $\bar{x}_2$ as médias das amostras e EP_d o erro padrão da diferença.

O cálculo dos graus de liberdade (GL) é a etapa final para determinar o valor crítico para aceitação ou rejeição da hipótese nula para um intervalo de confiança de 95% bicaudal, conforme Eq. (11):

$$GL = n_1 + n_2 - 2 \quad (11)$$

sendo GL os graus de liberdade e n_1 e n_2 são os tamanhos das amostras. Para um valor t de Student calculado menor que o valor crítico obtido a partir da tabela de percentis da distribuição de Student, aceita-se a hipótese nula (H_0), caso contrário, rejeita-se a H_0 . Para essa pesquisa, espera-se, como H_0 , que não haja diferenças significativas entre as amostras.

2.7 Experimentos

Para avaliar a robustez do modelo sugerido e explorar os limites da inferência em imagens instantâneas sob diferentes condições de amostragem temporal, foram planejados cinco experimentos distintos. A estratégia experimental procurou avaliar tanto a capacidade de generalização do modelo treinado com imagens de 5 minutos quanto a precisão de modelos treinados apenas com imagens de 2 minutos.

Os conjuntos de dados foram segmentados em subconjuntos de treinamento, validação e teste. Além das métricas convencionais de aprendizado profundo (mAP), um subconjunto específico das imagens de teste foi submetido a uma validação metrológica rigorosa por meio do TVC. Isso foi feito utilizando apenas os dados do dia 27 de março, quando houve controle simultâneo com a leitura manual da régua de marés.


2.7.1 DESCRIÇÃO DOS CENÁRIOS EXPERIMENTAIS

- Experimento 1: Este cenário utilizou imagens capturadas em intervalos regulares de 5 minutos, coletadas nos dias 26 e 27 de março de 2025. O modelo passou por um treinamento de 50 épocas. O objetivo foi comparar as leituras automáticas com as leituras manuais realizadas em gabinete. Para a análise de Van de Casteele, foram selecionadas 86 imagens do conjunto de teste referentes ao dia 27. A validação deste cenário inicial é estabelecida como pré-requisito metodológico, definindo o padrão de desempenho com o qual as variações de amostragem e de generalização dos experimentos subsequentes serão comparadas.
- Experimento 2: Para testar a capacidade de generalização do modelo frente à alteração no intervalo de captura das imagens, utilizaram-se os pesos treinados no Experimento 1, diretamente em um conjunto de teste inédito com 576 imagens de 2 minutos (Câmera 2, dias 26 e 27). A validação metrológica utilizou 363 dessas imagens (dia 27) para verificar se o aprendizado se mantém em capturas mais rápidas.

- c) Experimento 3: Buscou-se aumentar a diversidade do modelo, misturando dados das câmeras 1 e 2, com capturas de imagem em intervalos de 2 e 5 minutos, tanto no treinamento quanto na validação. O treinamento foi estendido para 100 épocas visando acomodar a maior heterogeneidade dos dados. O TVC foi aplicado especificamente a 317 imagens de 2 minutos do dia 27.
- d) Experimento 4: Neste experimento, a variável temporal foi isolada, utilizando apenas imagens com intervalo de 2 minutos dos dias 26 e 27, em todas as etapas (treinamento, validação e teste). Com 100 épocas de treinamento, o objetivo foi verificar se a especialização no intervalo de 2 minutos resultaria em desempenho superior em comparação à generalização ou aos dados mistos. O Teste de Van de Castele foi realizado com 226 imagens do dia 27.
- e) Experimento 5: O cenário mais restritivo utilizou apenas imagens com intervalo de 2 minutos, do próprio dia 27, para treinamento, validação e teste, ao longo de 100 épocas. Embora represente um cenário de menor volume de dados, serviu para analisar o comportamento do modelo durante o treinamento e o teste sob condições ambientais idênticas. As 67 imagens do conjunto de teste foram empregadas na análise metrológica.

A Figura 7 ilustra o fluxo metodológico adotado e a Tabela 4 apresenta os cenários experimentais delineados e quantifica o subconjunto de imagens submetido à validação pelo TVC.

Figura 7 – Fluxograma metodológico, contemplando a coleta de dados manual e automatizada, a preparação e o treinamento do modelo, a inferência e o pós-processamento, seguidos de avaliação de diferenças significativas, ajustes iterativos de hiperparâmetros (como a mudança do tamanho da imagem ou da taxa de aprendizado, caso os resultados iniciais fossem insatisfatórios), experimentos controlados, validação metrológica pelo Teste de Van de Castele e análise comparativa dos resultados.



Elaboração: Os autores (2026).

Tabela 4 – Resumo dos cenários experimentais

Experimento	Treino (quant. de imagens)	Validação (quant. de imagens)	Teste (quant. de imagens)	Total (quant. de imagens)	Frequência Treino/Val (minuto)	Frequência do Teste (minuto)	Épocas (unidade)	Amostra do TVC (quant. de imagens)
1	72	41	125	238	5	5 min	50	86
2	(Pesos do Exp. 1)	(Pesos do Exp. 1)	576	689	(Idem Exp. 1)	2 min	—	363
3	388	96	317	801	2 e 5	2 min	100	317
4	280	70	226	576	2	2 min	100	226
5	226	70	67	363	2	2 min	100	67

Elaboração: Os autores (2026).

3 RESULTADOS E DISCUSSÃO

A apresentação dos resultados ocorre em duas fases: primeiro, examina-se a eficácia do método sugerido (detecção e conversão métrica) no cenário base; depois, amplia-se a análise para comparar os diversos cenários experimentais e os sensores físicos convencionais.

3.1 Análise metodológica

A avaliação da matriz de confusão marcou o início da análise dos resultados do treinamento. Das 41 imagens fornecidas para validação do treinamento, a matriz indicou 41 verdadeiros positivos, sem falsos positivos nem falsos negativos. Em outras palavras, não houve casos em que o fundo (água do mar e estruturas locais) foi incorretamente classificado como régua de marés, nem vice-versa. Portanto, conforme demonstrado na Tabela 5, a classe régua de marés foi corretamente classificada. Ressalta-se que o índice de 100% de acerto na validação inicial decorre das características operacionais de uma estação de monitoramento de propósito fixo. Como a câmera e a régua de marés permanecem estáticas, a assinatura geométrica do fundo não sofre alterações estruturais, o que reduz a ocorrência de falsos positivos locais. No entanto, o desempenho perfeito do detector não pressupõe ausência de variabilidade: o conjunto de imagens avaliado foi exposto à dinâmica real do ambiente costeiro, englobando variações contínuas de luminosidade ao longo do dia, sombras complexas e mudanças hidrodinâmicas durante um ciclo completo de maré de sizígia. A robustez da detecção, portanto, reflete a capacidade da arquitetura YOLOv8n de isolar esses ruídos ambientais, focando estritamente nas feições estruturais de alto contraste da régua de marés.

Tabela 5 – Matriz de confusão.

Verdadeiro/Predito	Régua de marés	Fundo
Régua de marés	41	0
Fundo	0	0

Fonte: Soares et al. (2025).


A Figura 8 apresenta um resumo gráfico da evolução das perdas (*losses*) e das métricas de avaliação ao longo de 50 épocas. Os gráficos de treinamento (*train/box_loss*, *train/cls_loss*, *train/dfl_loss*) mostram uma redução consistente e gradual, indicando que o modelo aprendeu progressivamente. A curva suavizada (tracejada em laranja) mostra a tendência geral e ajuda a visualizar a melhoria contínua. Para os gráficos de validação (*val/box_loss*, *val/cls_loss*, *val/dfl_loss*), observa-se maior oscilação, mas com tendência de queda, o que indica boa generalização. A semelhança de comportamento observada nos gráficos de treino e de validação sugere que não houve sobreajuste (*overfitting*).

As métricas de precisão e de recuperação das caixas delimitadoras indicaram que o modelo detectou adequadamente a régua de marés. Uma mAP50 de 0,995 indica excelente desempenho com IoU de 50%, reforçando a qualidade da detecção. Já a mAP50-95 de 0,882 apresenta um valor menor devido ao rigor crescente dos limiares de IoU.

O eixo horizontal dos gráficos representa o número de épocas (*epochs*) do treinamento, enquanto o eixo vertical representa os valores das funções de perda (*loss functions*) e das métricas de desempenho associadas ao modelo, incluindo perda de localização (*box loss*), perda de classificação (*classification loss*),

perda distributiva focal (DFL *loss*), precisão (*precision*), sensibilidade (*recall*) e métricas de mAP. Valores decrescentes das funções de perda indicam convergência do modelo, enquanto valores crescentes de precisão, sensibilidade e mAP indicam melhoria no desempenho da detecção.

Figura 8 – Resumos gráficos do treinamento e da validação.



Fonte: Soares et al. (2025).

A etapa seguinte caracterizou-se pela devida conversão dos valores em pixel da caixa delimitadora inferior nas 125 imagens de teste que não participaram do treinamento. Utilizou-se a Eq. (1) como função de conversão de pixel para metro em cada imagem. Os valores métricos identificados nas imagens foram confrontados com os valores calculados pelo aprendizado profundo, e o resumo estatístico encontra-se na Tabela 6.

Tabela 6 – Resumo estatístico.

Estatística	Observações em gabinete (m)	Aprendizado Profundo (m)
Média	2,14	2,15
Erro Padrão	0,02	0,02
Desvio Padrão	0,26	0,26
Mínimo	1,40	1,43
Máximo	2,46	2,49


Fonte: Soares et al. (2025).

Para verificar se a diferença observada entre as médias populacionais era estatisticamente relevante, realizou-se o teste *t* de Student para amostras independentes. A aplicação das equações metodológicas resultou em um erro padrão da diferença (EP_d) de 0,0329 m e em uma estatística $t_{\text{calculado}} = 0,311$, associada a 248 graus de liberdade.

Confrontando o valor obtido com o limite tabelado para um intervalo de confiança bicaudal de 95% ($t_{\text{crítico}} = 1,970$), verifica-se que $t_{\text{calculado}} < t_{\text{crítico}}$. Portanto, aceita-se a hipótese nula (H_0), confirmando que não há diferenças estatisticamente significativas entre o nível d'água extraído visualmente em gabinete e os valores gerados automaticamente pela inferência do modelo YOLOv8n integrado à função polinomial. Esse resultado atesta o elevado rigor e a confiabilidade do método ótico proposto para a automação do fluxo de trabalho no TVC.

A Figura 9 apresenta a distribuição dos valores calculados pelo aprendizado profundo, bem como as referências que determinaram a função de conversão de pixels para metros. Percebe-se que os valores extrapolados mantiveram comportamento adequado, sem apresentar anomalias, conforme observado no resumo estatístico.

Figura 9 – Distribuição dos valores calculados pelo aprendizado profundo.



Fonte: Soares et al. (2025).

Demonstrada a eficácia do modelo no Experimento 1, tanto na detecção quanto na conversão métrica, a investigação foi estendida aos cenários de generalização e de variação temporal (Experimentos 2 a 5). Nesta etapa, a totalidade dos cenários propostos foi submetida à validação metrológica por meio do diagrama de Van de Castele, o que permitiu o confronto direto entre a inferência computacional e o método de referência convencional.

3.2 Análise comparativa dos experimentos (Teste de Van de Castele)

Conforme demonstrado no Experimento 1, a detecção foi altamente eficaz. Todos apresentaram matriz de confusão apenas com verdadeiros positivos, e as métricas de avaliação apresentaram valores robustos, conforme a Tabela 7. O Experimento 2 utilizou o treino do primeiro experimento. O Experimento 3, que possuía o maior conjunto de dados de treinamento, apresentou o melhor mAP50-95.

Tabela 7 – Resumo das métricas de avaliação.

Métricas	Experimentos 1 e 2	Experimento 3	Experimento 4	Experimento 5
mAP50	0,995	0,995	0,995	0,995
mAP50-95	0,882	0,913	0,844	0,874

Elaboração: Os autores (2026).

Um aspecto metodológico relevante diz respeito ao posicionamento da segunda câmera. Por estar instalada em um ângulo ligeiramente distinto da primeira, a função de conversão de valores demandou um ajuste específico para as imagens capturadas na frequência de 2 minutos para representar a relação entre a régua de marés e as imagens, conforme Tabela 8

Tabela 8 – Relação de escala entre a régua de marés e as imagens da câmera 2.

Régua de marés (m)	$\bar{y}$ (pxl)
2,90	139,11
2,50	294,03
2,20	386,08
1,70	507,88

Elaboração: Os autores (2026).

A Tabela 9 consolida os resultados de média (viés) e desvio padrão (DP) obtidos para os sensores de nível em comparação com o método convencional, bem como os resultados dos cinco experimentos de visão computacional. As siglas RAD e ENC referem-se, respectivamente, aos sensores Radar e Encoder.

Tabela 9 – Parâmetros estatísticos do Teste de Van de Castele para os sensores, em relação aos experimentos propostos e ao método tradicional, em metros.


Estatística	Convencional		Experimento 1		Experimento 2		Experimento 3		Experimento 4		Experimento 5	
	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC
Média	0,00	0,84	-0,01	0,83	-0,03	0,81	-0,04	0,81	-0,03	0,81	-0,03	0,81
DP	0,02	0,02	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03

Elaboração: Os autores (2026).

Observa-se que a leitura manual do método convencional, utilizada como referência, apresentou o menor desvio padrão (0,02 m). Os resultados dos modelos de aprendizado profundo convergiram para um desvio padrão de 0,03 m e um viés sistemático de mesma magnitude para ambos os sensores de nível em relação ao método convencional, com exceção do Experimento 1, que apresentou um viés ligeiramente menor. Esse comportamento estável, mesmo com a variação das frequências de amostragem e a troca de câmeras, demonstra a robustez do método, embora evidencie os limites impostos pela captura instantânea de imagens diante da dinâmica da superfície da água.

A análise da Figura 10 evidencia que os experimentos automatizados geram um volume de dados maior do que o gerado pelo método convencional. Entretanto, observa-se uma limitação temporal na técnica óptica: enquanto o observador humano registrou leituras até às 19h00, respeitando um ciclo de maré completo e alcançando a cota de 1,2 m na régua de marés, a detecção via câmera restringiu-se às 18h00 devido à redução da luminosidade natural. Ainda de acordo com a Figura 10, o TVC não aponta anomalias nos sensores de nível, o que constitui um indicativo favorável para o processo de automação do teste.

Figura 10 – Diagramas do Teste de Van de Castele para cada cenário experimental.



Elaboração: Os autores (2026).

4 CONSIDERAÇÕES FINAIS

O Teste de Van de Castele convencional atua principalmente como uma ferramenta reativa de controle de qualidade, detectando erros, muitas vezes, após o comprometimento dos dados. Embora sua realização com periodicidade regular seja recomendada, a detecção de problemas, como deslocamentos ou assoreamento, pode levar à invalidação de séries temporais inteiras antes do diagnóstico. Essa abordagem reativa tende a gerar lacunas ou inconsistências nos dados, o que exige ações corretivas tardias.

Diante desse cenário, a presente pesquisa demonstrou a viabilidade técnica da automação do TVC por meio de visão computacional. Os resultados da aplicação do modelo YOLOv8 indicaram convergência eficiente, com métricas de precisão e recuperação próximas de 1,0 e mAP50-95 consistentemente acima de 0,84 em todos os cenários experimentais. A análise estatística confirmou a robustez do método, com a matriz de confusão evidenciando a ausência de erros de classificação e o teste *t* de Student validando a concordância entre as leituras automáticas e a referência de gabinete.

No que tange à precisão metrológica, o modelo computacional apresentou um desvio padrão médio de 0,03 m, ligeiramente superior ao de 0,02 m obtido pelo método convencional. Essa diferença marginal, somada ao viés sistemático identificado, pode ser atribuída à natureza da amostragem: a captura instantânea da imagem fixa a condição instantânea da superfície do mar, registrando ruídos de alta frequência (ondas) que são filtrados tanto pelos sensores de nível, que operam por integração temporal, quanto pelo observador humano, que deduz uma média visual. Além disso, oscilações na estrutura experimental de sustentação das câmeras, mais suscetíveis à ação do vento (vibração e movimento), podem ter contribuído para a variabilidade residual. Contudo, essas características não inviabilizam o método; pelo contrário, confirmam que a técnica é robusta para fins de controle de qualidade, desde que se considerem as limitações físicas da inferência instantânea.

A automação proposta apresenta uma abordagem promissora para aumentar a eficácia do monitoramento do nível do mar. Ao permitir uma análise contínua e de alta frequência, o sistema inteligente pode identificar desvios sutis no comportamento operacional que antecedem falhas críticas. Isso viabiliza intervenções proativas, como o agendamento de manutenção para desobstrução dos tubos de tranquilização antes que o assoreamento invalide os dados, ou a recalibração de sensores antes que um desvio se torne significativo. A relação custo-benefício favorece a abordagem automatizada, pois o investimento inicial em *hardware* de baixo custo é compensado pela eliminação dos custos associados às atividades de campo, o que permite uma frequência de validação que seria economicamente insustentável com o método manual. Além disso, o aprendizado profundo demonstra capacidade de otimizar os ciclos de calibração ao se adaptar continuamente às características de desempenho a longo prazo dos marégrafos.

Para trabalhos futuros, pretende-se expandir esta avaliação a outros marégrafos da RMPG, implementando a transmissão autônoma de dados por meio de redes sem fio. Para aprimorar a robustez da coleta, recomenda-se a substituição do suporte de alumínio por materiais mais resistentes às intempéries e a investigação de sistemas de iluminação auxiliar, a fim de superar as restrições ao monitoramento noturno. Do ponto de vista metodológico, sugere-se a definição de um modelo de coleta intensiva em períodos específicos do TVC. Essa estratégia permitiria calcular a média temporal das imagens, mitigando os efeitos de alta frequência observados nesta pesquisa.

Agradecimentos

Os autores agradecem ao Instituto Brasileiro de Geografia e Estatística (IBGE) pela cessão dos dados e pela concessão de afastamento temporário ao primeiro autor para a realização do Programa de Pós-Graduação *stricto sensu*; e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pelo apoio financeiro concedido por meio de bolsa de doutorado (Código de Financiamento 001).

Contribuição dos Autores

Conceptualização: Soares, S.; Santos, E.G.; Reinheimer, L.F.; e Dalazoana, R.; Curadoria dos Dados: Soares, S.; Santos, E.G.; e Reinheimer, L.F.; Análise Formal e Investigação: Soares, S. e Dalazoana, R.; Metodologia: Soares, S.; Santos, E.G.; e Reinheimer, L.F.; Supervisão: Dalazoana, R.; Redação - minuta

inicial: Soares, S.; Santos, E.G.; Reinheimer, L.F.; Inoue, M.E.B.; e Dalazoana, R.; Redação - revisão e edição: Soares, S.; Santos, E.G.; Reinheimer, L.F.; Inoue, M.E.B.; e Dalazoana, R.

Conflitos de Interesse

Os autores declaram não haver conflitos de interesse.

Referências

- Birol, F., Bignalet-Cazalet, F., Cancet, M., Daguze, J.-A., Fkaier, W., Fouchet, E., Léger, F., Maraldi, C., Niño, F., Pujol, M.-I., & Tran, N. (2025). Understanding uncertainties in the satellite altimeter measurement of coastal sea level: insights from a round-robin analysis. *Ocean Science*, 21, 133–150. <https://doi.org/10.5194/os-21-133-2025>.
- Centro de Hidrografia da Marinha – CHM. (2025). *Tábuas de Maré 2025*. <https://www.marinha.mil.br/chm/tabuas-de-mare?page=0>.
- Dalazoana, R., Luz, R.T., Lima, S.R.S., Miranda, Fr. A., Palmeiro, A.S., Miranda, Fa. A. e Freitas, S. R. C. (2005). *Controle vertical das RRNN e da posição geocêntrica do marégrafo no Porto de Imbituba*. [Trabalho apresentado]. IV Colóquio Brasileiro de Ciências Geodésicas, Curitiba. <https://artigos.ibge.gov.br/artigos-home/geodesia/2008-2005>.
- Del Rosso, M. P., Sebastianelli, A. P., Aparício, S. P., & Wheeler, J. P. (2021). How to create a proper EO dataset. In: *Artificial Intelligence Applied to Satellite-based Remote Sensing Data for Earth Observation*. IET. (pp. 113–130). https://doi.org/10.1049/PBTE098E_ch6.
- Freitas, G. T. M. (2022). Software para identificação de defeitos na superfície de pavimentos rodoviários utilizando Deep Learning. 109 f. [Dissertação de mestrado, Universidade Federal do Ceará – UFC]. <http://www.repositorio.ufc.br/handle/riufc/69600>
- Gemael, C. (2019). *Introdução à geodésia física*. Editora UFPR.
- Google. (2026). *Google Colab* [Software]. <https://colab.research.google.com/>
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2010). *Instruções técnicas para controle geodésico de estações maregráficas – CGEM e sua vinculação vertical ao Sistema Geodésico Brasileiro – SGB*. IBGE. https://geoftp.ibge.gov.br/metodos_e_outros_documentos_de_referencia/revista_e_manuais_tecnicos/mt_g11.pdf
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2021). *Monitoramento da variação do nível médio do mar nas estações da Rede Maregráfica Permanente para Geodésia: 2001–2020*. IBGE. <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101890.pdf>
- Intergovernmental Oceanographic Commission – IOC. (2024). *State of the Ocean Report*. IOC-UNESCO. (IOC Technical Series, 190). <https://doi.org/10.25607/4wbq>.
- Jähne, B. (2005). *Digital Image Processing*. [S.l.]: Berlin: Springer. <https://doi.org/10.1007/3-540-27563-0>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>
- Lima, J. M. C. (2019). Reconhecimento e análise de rachaduras a partir de imagens para monitoramento em regiões com atividade sísmica frequente. [Dissertação de mestrado, Universidade Federal de Alagoas - UFAL]. Programa de Pós-Graduação em Informática. Maceió, Alagoas. <http://www.repositorio.ufal.br/handle/riufal/7280>
- Lin, T.-Y., Maire, M., Belongie, S., Lubomir Bourdev, Girshick, R., Hays, J., Perona, P., Ramanan, D., C. Lawrence Zitnick, & Piotr Dollár. (2014). Microsoft COCO: Common Objects in Context. *ArXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1405.0312>
- Miguez, B. M., Testut, L., & Wöppelmann, G. (2008). The Van de Casteele test revisited: an efficient approach to tide gauge error characterization. *Journal of Atmospheric and Oceanic Technology*, 25(7). DOI: <https://doi.org/10.1175/2007JTECHO554.1>

- Mucci, T. (2024). *Overfitting vs. underfitting*. Ibm.com. <https://www.ibm.com/br-pt/think/topics/overfitting-vs-underfitting>
- Sánchez, L., & Sideris, M. G. (2017). Vertical datum unification for the International Height Reference System (IHRs). *Geophysical Journal International*, 209(2), 570–586. <https://doi.org/10.1093/gji/ggx025>.
- Silveira, L. N. (2023). *Aplicação de dados altimétricos orbitais e nivelamento hidrográfico em corpos hídricos continentais para a integração de referenciais verticais*. [Tese de doutorado, Universidade Federal do Rio Grande do Sul]. Lume Repositório Digital. <http://hdl.handle.net/10183/272222>.
- Skalski, P. (2022). *Make Sense* (versão 1.11.0). <https://www.makesense.ai/>; <https://github.com/SkalskiP/make-sense>
- Soares, S., Dalazoana, R., Inoue, M. E. B., Dos Santos, E. G., & Reinheimer, L. F. (2025). *Investigação preliminar do aprendizado profundo no teste de Van de Castele na estação maregráfica de Arraial do Cabo/RJ*. [Trabalho apresentado]. I Congresso Internacional de Regularização Fundiária & VIII Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação (I CIRF & VIII SIMGEO), Recife. <https://doi.org/10.5281/zenodo.17135655>.
- SONEL. (2019). *Quality control of the measurements published by SHOM*. https://www.sonel.org/_Quality-control-of-the.html.
- Srivastava, A., Dalvi, A., Britto, C., Rai, H., & Shelke, K. (2020). Explicit content detection using Faster R-CNN and SSD MobileNet v2. *International Research Journal of Engineering and Technology*, 7(3). <https://www.irjet.net/archives/V7/i3/IRJET-V7I31126.pdf>.
- Taye, M. M. (2023). Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions. *Computation*, 11(52). <https://doi.org/10.3390/computation11030052>.
- Terven, J., Córdova-Esparza, D.-M., & Romero-González, J.-A. (2023). A comprehensive review of YOLO architectures in computer vision. *Machine Learning and Knowledge Extraction*, 5, 1680–1716. <https://doi.org/10.3390/make5040083>.
- Torge, W., & Müller, J. (2012). *Geodesy* (4a. ed.). Walter de Gruyter.
- ULTRALYTICS. (2023). *YOLOv8*. <https://docs.ultralytics.com/models/yolov8/>.
- UNESCO. Intergovernmental Oceanographic Commission. (1985). *Manual de medição e interpretação do nível do mar*. IOC. https://www.jodc.go.jp/info/ioc_doc/Manual/065061eb.pdf
- UNESCO. Intergovernmental Oceanographic Commission. (2002). *Manual on sea level measurement and interpretation: reappraisals and recommendations as of the year 2000*. IOC. <https://unesdoc.unesco.org/ark:/48223/pf0000125129?posInSet=1&queryId=f96ff20a-ffad-4228-98d2-81751401754f>
- UNESCO. Intergovernmental Oceanographic Commission. (2016). *Manual on sea level measurement and interpretation: radar gauges*. IOC. <https://unesdoc.unesco.org/ark:/48223/pf0000246981?posInSet=2&queryId=f96ff20a-ffad-4228-98d2-81751401754f>
- Zeng, J., Zhong, H. (2024). YOLOv8-PD: an improved road damage detection algorithm based on YOLOv8n model. *Sci Rep* 14, 12052. <https://doi.org/10.1038/s41598-024-62933-z>

Biografia do autor principal



Salomão Soares, natural do Rio de Janeiro, nascido em 1980. É Engenheiro Cartógrafo pela Universidade do Estado do Rio de Janeiro (UERJ, 2003) e Mestre em Estudos Populacionais e Pesquisas Sociais pela Escola Nacional de Ciências Estatísticas (ENCE, 2006). Atualmente, é doutorando em Ciências Geodésicas pela Universidade Federal do Paraná (UFPR). Atua como Tecnologista no Instituto Brasileiro de Geografia e Estatística (IBGE), na Coordenação de Geodésia. Seus interesses de pesquisa incluem sistemas de referência vertical, altimetria por satélite e maregrafia.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.