

Rastreamento de marcas de calado em navios baseado em Haar Cascade

Witalo Pietler P. de Sousa* Flávio Machado*
Ricardo da Mota Salvador* Raquel Frizera Vassallo*

* Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: witalopietler@gmail.com, k.flaviomachado@gmail.com, ricardomsalvador@hotmail.com, raquel@ele.ufes.br)

Abstract: Draft measurement is a fundamental task in the maritime transport of bulk cargo, being necessary to ensure the distribution of cargo and the stability of the ship, in addition to transferring the correct amount of cargo. Therefore, the method presented on this paper was proposed with the intention of helping manual operators as well as serving as an important tool for the automation of the function. The proposal of the paper is to offer a solution capable of detecting the sets of ship's draft marks, through the training of a Haar Cascade algorithm and digital image processing, and to perform the positional control of a camera, in order to keep it centralised in the image the draft marks. The application works through a client-server architecture, in which the server is on land and the client, equipped with a camera and a microprocessor, can be installed on autonomous land or maritime vehicles, or even in fixed structures installed in strategic locations.

Resumo: A medição de calados é uma tarefa fundamental no transporte marítimo de cargas a granel, sendo necessária para garantir a distribuição das cargas e a estabilidade do navio, além da transferência da quantidade correta de carga. Desta forma, o presente trabalho foi proposto com o intuito de auxiliar os trabalhadores da área bem como servir como uma importante ferramenta para automatização da função. A proposta do trabalho é oferecer uma solução capaz de detectar os conjuntos de marcas de calado de navio, através do treinamento de um algoritmo Haar Cascade e processamento digital de imagens, e realizar o controle do posicionamento de uma câmera, de modo a manter centralizada na imagem as marcas de calado. A aplicação funciona através de uma arquitetura cliente-servidor, na qual o servidor fica em terra e o cliente, equipado com uma câmera e um microprocessador, pode ser instalado em veículos autônomos terrestres ou marítimos, ou ainda em estruturas fixas instaladas em locais estratégicos.

Keywords: Draft Survey; Haar Cascade; Object Detection; Object Tracking.

Palavras-chaves: Medição de Calado; Haar Cascade; Detecção de Objetos; Rastreamento de objetos.

1. INTRODUÇÃO

O transporte marítimo de cargas é essencial para a economia mundial. Por ser uma das opções mais viáveis economicamente e com menores impactos ambientais, segundo UNCTAD (2020a) o transporte de bens por vias marítimas corresponde a cerca de 80% de todo o comércio internacional. Dentre os produtos transportados, as cargas a granel correspondem a cerca de 34% de todo o volume transportado, chegando no ano de 2020 a 3,22 bilhões de toneladas (UNCTAD, 2020b). No Brasil, os produtos a granel representam a maior parte da exportação, sendo a soja e o minério de ferro, juntos, responsáveis por 27% de toda a exportação do país no mesmo período. Isso representa um valor FOB (*Free on Board*) de US\$ 51,2 bilhões segundo o Ministério da Indústria (2020).

* Apoio financeiro através do Projeto 523/2016 - Edital FAPES/VALE/FAPERJ No.01/2015 - Pelotização, Meio Ambiente e Logística.

Apesar da grande importância da carga a granel para o comércio mundial, pouco tem sido feito para a automatização dos processos de carga e descarga nos portos. O carregamento de navios graneleiros é um processo lento que precisa de supervisão constante para garantir a distribuição das cargas e a estabilidade do navio, além da transferência da quantidade correta de carga. Esse monitoramento se dá pelo processo de leitura e medição do calado.

Atualmente, a medição de calado é feita de forma manual e sua leitura depende de que um profissional se aproxime do navio para inspecionar visualmente as marcas de calado, que representam a distância da quilha do navio até a superfície da água. Esta distância indica o volume submerso do navio e, a partir das dimensões do navio e a densidade da água onde o mesmo se encontra, é possível estimar a quantidade de material carregado ou descarregado usando-se a leitura do calado. Sendo assim, a realização in loco desta tarefa expõe o profissional aos riscos do ambiente portuário. Entretanto, tal leitura poderia ser realizada de

forma remota, ou até mesmo automática, aumentando a segurança na realização da tarefa e a eficiência portuária, uma vez que a agilidade na leitura do calado pode ser revertida em menor tempo de carregamento e, consequentemente, menor tempo do navio ancorado.

Nos últimos anos, alguns esforços foram feitos com o intuito de automatizar o processo de medição de calado como os trabalhos de Machado et al. (2018), Ferreira et al. (2018) e Machado (2020), tendo diversos deles obtido resultados promissores. Esses trabalhos propõem sistemas que realizam a medição automaticamente, substituindo a expertise de um operador humano. Entretanto, como a tarefa de medição de calado é uma tarefa extremamente vital à operação dos portos, navios e empresas envolvidas, podendo uma falha acarretar em danos ambientais e econômicos aos interessados, tais sistemas ainda precisam ser muito refinados e testados antes da implantação, mantendo o processo estagnado com os problemas atuais.

Existe ainda, no ambiente portuário, uma resistência à implantação de um sistema automatizado. Muitos profissionais e capitães de navio ainda preferem que a medição seja feita por um arqueador, profissional responsável pela leitura de calados e conhecimento de parâmetros intrínsecos do navio. Mesmo assim, acredita-se que a implantação de um sistema de medição automática de calado possa ser realizada e continuamente comparada com as leituras feitas por tais profissionais, até que se crie uma relação de confiança com o método automático.

Tanto no caso de uma medição automática quanto manual, o ideal é que a leitura seja feita com a marcação do navio no centro do campo visual da câmera ou do arqueador. Dessa forma, este trabalho propõe uma infraestrutura baseada em visão computacional para auxiliar a leitura de calado, seja ela automática ou manual. O sistema será capaz de posicionar câmeras instaladas no porto ou embarcadas em veículos autônomos ou lanchas portuárias, de forma que seja possível realizar a leitura do calado através das imagens de tais câmeras.

O restante deste artigo está organizado da seguinte forma. Na Seção 2 são citados alguns trabalhos relacionados. Na Seção 3 é descrita a solução proposta para se controlar a orientação de uma câmera, de tal forma que a marcação do calado fique sempre próxima ao centro da imagem. A seguir, na Seção 4, são apresentados os experimentos e uma discussão dos resultados. Finalmente, na Seção 5 são feitas as conclusões e definidos os trabalhos futuros.

2. TRABALHOS RELACIONADOS

A leitura de calado é uma das etapas mais importantes do processo de arqueação, que visa determinar o volume de água deslocado pelo navio, e consequentemente a quantidade de carga existente no mesmo. Para que ela ocorra, é necessário que o arqueador se aproxime da embarcação, tal como mostrado na Figura 1 e observe o deslocamento vertical do navio através da escala formada pelas marcas de calado. Existem seis conjuntos de marcas de calado distribuídos a popa, meia-nau e proa, e é necessário que seja feita a leitura em todas estas regiões para se manter a integridade estrutural do navio. Este processo é feito de forma manual a mais de 40 anos, e é extremamente




Figura 1. Exemplo de marcas de calado de um navio.

desgastante para o profissional, uma vez que deve ser repetido diversas vezes enquanto o navio está ancorado.

Alguns trabalhos buscaram automatizar o processo, entregando uma medição de calado, e tentando substituir o arqueador. Tsujii et al. (2016), por exemplo, tenta identificar as marcas de calado utilizando *Template Matching*, seguido por um conjunto de operações morfológicas aplicadas em uma sequência de *frames* para determinar a linha d'água, e regressão do valor do calado ao juntar ambas informações. Tal método é custoso computacionalmente e tem como objetivo final a leitura completa do calado, partindo do princípio que a câmera já está posicionada para a leitura. Além disso, a utilização de *template matching* acaba sendo um problema na etapa de identificação das marcas de calado, uma vez que mudanças no ângulo de visada poderiam acarretar em falhas na detecção.

Trabalhos mais recentes, como Machado et al. (2018) e Ferreira et al. (2018), tentam abordar etapas separadas do problema, tendo o primeiro proposto um método de detecção da linha d'água utilizando um banco de filtros, e o segundo um método de leitura das marcas de calado utilizando OCR. Apesar de apresentarem resultados promissores, ambos os trabalhos partem do pressuposto que a câmera deve estar posicionada de forma a capturar apenas as regiões de interesse para a leitura de calado, obtendo assim resultados ruins quando as imagens não focam nas marcas de calado. Os dois trabalhos não propuseram uma metodologia para a leitura completa do calado, porém ambos serviram de motivação para o trabalho de Machado (2020) que propõe um pipeline completo para a medição de calado utilizando redes neurais convolucionais.

Assim, Machado (2020) faz uso de redes neurais convolucionais para as duas principais tarefas, detecção da linha d'água e detecção das marcas de calado. Para a tarefa de detecção de linha d'água é utilizada uma arquitetura de segmentação semântica, que identifica e separa a região do mar, enquanto para a detecção das marcas de calado é utilizada uma arquitetura de detecção de objetos. Os resultados obtidos foram promissores, e a utilização de métodos de aprendizado de máquinas permite a identificação mais confiável das marcas de calado, podendo assim ser adaptado para controle de câmeras em ambientes portuários de forma a focá-las nas marcas de calado. Porém, o elevado custo computacional de ambas arquiteturas dificulta a escalabilidade da solução, tornando-a inviável de ser embarcada em veículos autônomos, ou ter seus processos replicados no servidor para controlar múltiplas câmeras.

Na questão de detecção de objetos, algumas abordagens como Haar Cascade (Viola and Jones, 2001) e HOG (*His-*

tograms of oriented gradients) (Dalal and Triggs, 2005) estão entre as mais populares. Inicialmente aplicadas para detecção de faces, estes métodos passaram a ser também generalizados e utilizados para detecção de objetos em geral como em Chayeb et al. (2014) e Rastogi et al. (2017).

Além de ser usado para detecção de objetos, o Haar Cascade é muitas vezes aplicado para detecção e rastreamento de objetos. Em Wanjale et al. (2013), Haar Cascade é usado para detecção e rastreamento de faces em um sistema de monitoramento e segurança, enquanto em Flores-Delgado et al. (2017) o objetivo é capacitar um drone a rastrear uma face e segui-la durante o seu movimento.

Nos últimos dez anos, as melhorias de hardware dedicado a processamento de imagens e vídeos, como as GPUs (*Graphics Processing Units*), e a diminuição nos preços para sua aquisição impulsionou o desenvolvimento e fortalecimento das redes neurais profundas, as quais têm sido muito utilizadas para detecção e rastreamento de objetos. Tais abordagens são atualmente as mais promissoras e inúmeras delas podem ser encontradas na literatura, como o detector de objetos YOLO, proposto por Redmon et al. (2016), baseado na arquitetura Darknet; o uso de redes siamesas para rastreamento e re-deteção de objetos (Voigtlaender et al., 2020); e o Deep SORT, uma melhoria do método SORT proposto por (Wojke et al., 2017), que se apresenta como uma abordagem promissora para detecção e rastreamento de múltiplos objetos.

Apesar das melhorias que estas abordagens podem trazer, o custo computacional, tempo de resposta e o gasto de energia tornam algumas dessas soluções inviáveis de serem aplicadas em ambientes reais, onde pode ser necessária uma solução embarcada ou com alta escalabilidade. Nessas situações, é possível utilizar das vantagens de técnicas tradicionais de detecção e rastreamento de objetos, as quais podem contornar diversas destas limitações.

Este é o caso do problema abordado neste trabalho, o qual inclui a detecção de um único objeto na cena (a marca do calado no casco do navio), que possa funcionar de forma embarcada em um hardware simples e funcione em tempo real. Por esses motivos, foi feita a opção pelo uso do Haar Cascade para a detecção e rastreamento, assim como técnicas de processamento digital de imagens para pré e pós-processamento das mesmas.

3. SOLUÇÃO PROPOSTA

Para se obter um sistema que possa auxiliar na medição do calado através do posicionamento das câmeras, a solução proposta foi dividida nas partes da infraestrutura e rastreamento das marcas de calado.

3.1 Infraestrutura

A infraestrutura proposta consiste em uma arquitetura cliente-servidor, na qual o servidor, em terra, consome as imagens da câmera e envia comandos para o(s) cliente(s), que podem estar em uma embarcação autônoma terrestre ou marítima, ou em estruturas fixas instaladas em locais estratégicos do porto.

O cliente, representado em azul na Figura 2, é composto por uma câmera, equipada com um estabilizador capaz de

realizar os movimentos (Roll, Pitch e Yaw), e um microcomputador, capaz de fazer a interface entre o servidor e a câmera através de sua interface de rede. Responsável pelo controle dos clientes, o servidor, representado em verde na Figura 2, realiza o processamento das imagens, envio das mensagens de controle da câmera e acesso do usuário para que o mesmo possa controlar a câmera, visualizar as imagens e auditar o processo como um todo.

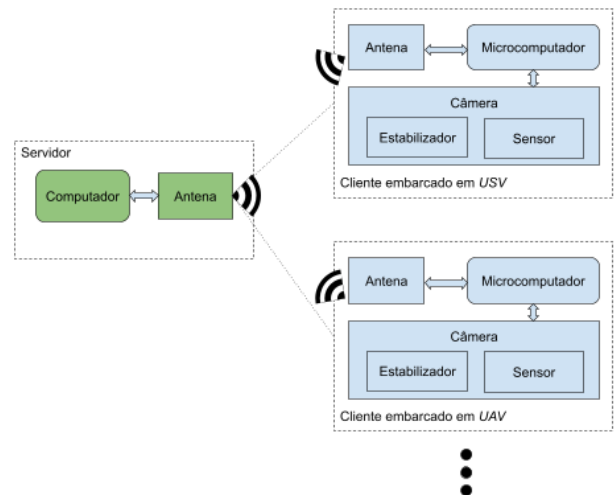


Figura 2. Esquemático do fluxo de informações e as interações entre os principais agentes.

A comunicação entre cliente-servidor é feita através de uma interface de rede sem fio, e propõe-se a utilização de antenas dedicadas para a comunicação, uma vez que a banda utilizada para a transmissão de imagens depende da qualidade das imagens e quantidade de clientes instalados.

3.2 Rastreamento das marcas de calado

O método proposto parte do princípio que as imagens recebidas são de ambientes portuários. Porém, devido à diversidade dos modelos de câmeras e diferentes condições de iluminação, é necessária uma etapa de pré-processamento, para que as imagens recebidas sejam redimensionadas para 480 x 270 pixels e transformadas em monocromáticas, conforme mostrado na Figura 3.

Após a etapa de pré-processamento, o método de detecção utilizado foi o Haar Cascade (Viola and Jones, 2001) devido ao fato de ser considerado uma técnica rápida, eficiente e de baixo custo computacional. Isso possibilitou que a coleta da imagem, o processamento, o envio do comando ao servidor e resposta da câmera ocorresse em tempo hábil para uma aplicação em tempo real.

A saída do Haar Cascade são as *bounding boxes* dos conjuntos de marcas de calado encontrados na imagem. Quando algum conjunto é encontrado, é verificado se a detecção é única. Caso não seja, é realizado um pós-processamento utilizando técnicas clássicas de processamento digital de imagens (Gonzalez and Woods, 2008) e heurística a fim de selecionar a detecção que se acredita ser a correta.

Tal pós-processamento tem o objetivo de definir uma região de interesse, onde é mais provável que se encontre a marcação de calado. Para isso, aplica-se na imagem um filtro Gaussiano para redução de ruídos, seguido por

um detector de bordas Canny (Figura 4). Identificadas as bordas dos objetos, os mesmos são separados e filtrados, descartando-se aqueles com largura superior a 24 pixels ou altura superior a 14 pixels (5% da resolução horizontal e vertical da imagem), ou ainda largura ou altura inferior a 3 pixels. Tais valores foram escolhidos empiricamente de acordo com a área que os números, caracteres e marcações costumam ocupar na imagem. Inicialmente a região de interesse é definida como a região mais densa da imagem restante, sendo que a densidade das regiões é definida usando-se apenas a posição horizontal dos elementos. O resultado dessa etapa pode ser visto na Figura 5 (marcação em azul). Depois disso a região de interesse é recentralizada para o ponto mediano da região mais densa, como mostrado na Figura 5 (marcação em vermelho).




Figura 3. Conversão para tons de cinza e resolução 480x270.




Figura 4. Detecção de bordas utilizando o filtro de Canny.

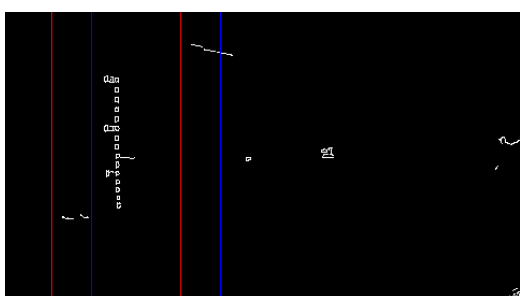


Figura 5. Filtragem de acordo com o tamanho, seleção da área mais densa (azul) e recentralização no ponto mediano da região mais densa (vermelho).

A seguir é realizada uma supressão de não máximos, que descarta todas as detecções do Haar Cascade com exceção daquela mais próxima ao centróide da região de interesse.

Para se melhorar ainda mais os resultados obtidos com o detector, foi aplicada uma filtragem temporal para evitar que falsos positivos em uma única imagem influenciassem o posicionamento da câmera. Assim, mantém-se um histórico das últimas 5 detecções, o qual é utilizado para definir se uma nova detecção é confiável. Caso as distâncias entre

as detecções historiadas e a nova detecção forem menores que um intervalo de tolerância pré-estabelecido, a detecção é considerada confiável. Caso contrário, a detecção é armazenada no histórico e desconsiderada, ou seja, nenhum comando é enviado para o cliente.

Sempre que a detecção alcança a confiabilidade desejada, a mesma é utilizada para a definição de um novo movimento para a câmera. Para isso, é calculada a distância entre o centro da *bounding box* e o centro da imagem. Se este valor for maior que o intervalo de tolerância configurado, é enviado um comando ao cliente para que o mesmo reposicione a câmera de forma que o centro da *bounding box* coincida com o centro da imagem.

O fluxograma mostrado na Figura 6 ilustra o funcionamento do processo de rastreamento das marcas de calado.

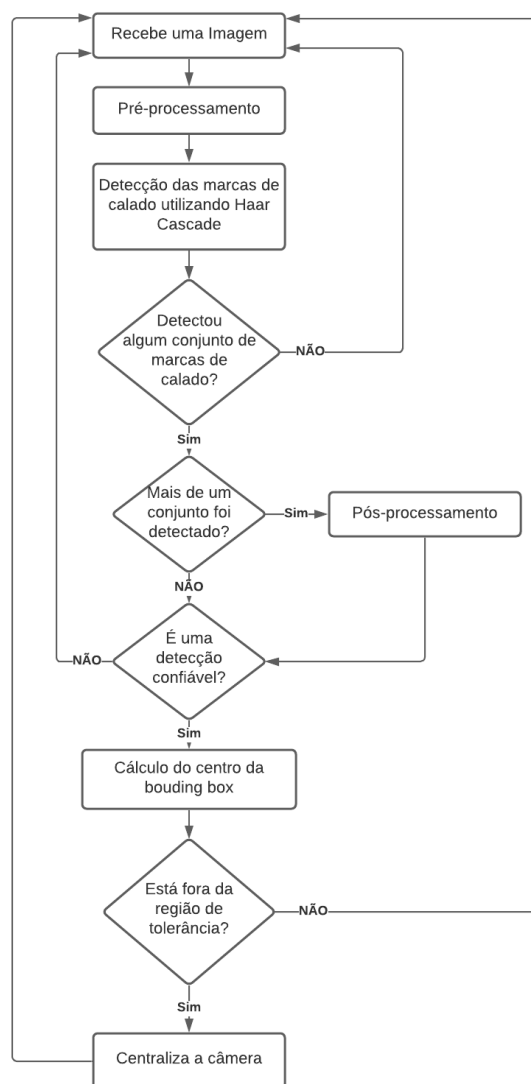


Figura 6. Fluxograma do processo de rastreamento das marcas de calado.

4. EXPERIMENTOS E RESULTADOS

Neste projeto, o equipamento utilizado incluiu uma câmera com compensação de movimento, modelo Foxtech SEEKER-10 360º, e o microcontrolador Raspberry Pi 4. O

driver de interface entre o servidor e a câmera foi criado especificamente para essa aplicação, sendo responsável pelo controle da câmera. Devido a limitações do equipamento, um controle preciso de orientação da câmera não foi possível, ficando a aplicação limitada a atuar com uma margem de tolerância, ou seja, é possível posicionar a câmera dentro de uma faixa de tolerância mas não precisamente em uma orientação específica. Apesar disso, tal limitação não impacta negativamente no sistema de rastreamento proposto, dado que um erro com algumas dezenas de pixels do posicionamento da marca de calado em relação ao centro da imagem não prejudica a sua leitura.

As imagens para treinamento do Haar Cascade foram obtidas de vídeos gravados nas áreas portuárias onde a solução será aplicada. Desses vídeos foram selecionadas 855 imagens negativas (sem a presença das marcas de calado) retiradas de 7 cenas diferentes. Já as imagens positivas (com a presença das marcas de calado) foram criadas utilizando recortes do objeto de interesse em diferentes cenas, e aplicando-se variações de escala, posição e angulação (*Roll*, *Pitch* e *Yaw*), garantindo assim um banco de imagens mais variado. Para isso, foi utilizada uma ferramenta disponível no OpenCV (2015), que mescla imagens do objeto de interesse com imagens negativas. Utilizando essa ferramenta, foram criadas 600 imagens positivas, a partir de 12 imagens de marcas de calado retiradas de diferentes cenas e o banco de imagens negativas já citado.

4.1 Teste de detecção das marcas de calado

Os primeiros testes foram feitos para comprovar o funcionamento do detector. Para isso, a aplicação foi avaliada utilizando-se as métricas de verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN). A partir de seus valores foram calculados o *recall*, *precision* e *F-Score*, que são métricas normalmente utilizadas na literatura e, portanto, facilitam a comparação com outros trabalhos.

$$recall = \frac{VP}{VP + FN} \quad (1)$$

$$precision = \frac{VP}{VP + FP} \quad (2)$$

$$F-Score = \frac{2 \times precision \times recall}{precision + recall} \quad (3)$$

Foram utilizados 4 vídeos gravados sobre uma lancha em torno de diferentes navios, de onde foram retiradas 50 imagens de cada vídeo em que a régua do calado sempre aparece. Todas as imagens foram rotuladas, gerando um banco de imagens e seus respectivos *groundtruths*. A Figura 7 exemplifica uma imagem e seu *groundtruth*. Além disso, também foram selecionadas 200 imagens negativas, provindas de quatro cenas distintas (50 imagens por cena).

Nas imagens positivas só foram consideradas detecções verdadeiramente positivas aquelas em que o centro da *bounding box* estava dentro da região de régua rotulada no *groundtruth* (região branca). Caso contrário, a detecção foi considerada falsa positiva.

Os resultados obtidos dos testes com um total de 400 imagens estão representados na Tabela 1.




Figura 7. Imagem positiva e o respectivo groundtruth.

Tabela 1. Métricas de acerto, erro e avaliação.

Acerto e Erro		Avaliação	
Métrica	Quantidade	Métrica	Percentual
VP	158	Recall	79.40
FP	3	Precision	98.14
VN	198	F-Score	87.78
FN	41		

Para o rastreamento da marcação de calado, a ocorrência de falsos positivos é mais prejudicial do que a ocorrência de falsos negativos, uma vez que sucessivas detecções de falsos positivos podem levar a câmera a rastrear o objeto errado, retirando o foco das marcas de calado. Por outro lado, a ocorrência de falsos negativos não gera um comando de movimentação e, portanto, não alterará a posição da câmera. Isso permite que, na imagem seguinte, caso uma nova detecção seja realizada e classificada corretamente, haja o reposicionamento da câmera para a realização do rastreamento. Dessa forma, percebe-se que os resultados obtidos pelo detector proposto estão alinhados com as prioridades da solução proposta para o problema, apresentando uma alta taxa de *precision* e um *recall* satisfatório.

4.2 Teste de validação do rastreador

Devido à pandemia causada pelo Covid-19, não foi possível realizar um teste no porto para validação do rastreador implementado. Desta forma, foi realizada uma emulação que se assemelha ao que seria realizado in loco. Utilizando-se uma televisão que exibia uma cena do porto, a marca do calado foi movida de diversas formas a fim de testar se a câmera, com o rastreador em funcionamento, era capaz de acompanhar os movimentos conforme programado.

Para comparação com uma situação onde não há um rastreador funcionando, a câmera foi inicialmente estabilizada e o vídeo foi executado com o sistema proposto desligado. Em um segundo momento, o rastreador foi ligado e o vídeo repetido. No gráfico da Figura 8, nota-se que o rastreador atua para centralizar as marcas de calado, sempre que essas ultrapassam o limiar da faixa de tolerância (curva em vermelho). No mesmo gráfico, também é possível visualizar o erro de posicionamento da marca de calado em relação ao centro da imagem, quando não há a atuação do rastreador (curva em verde). Nesse caso, a marca se aproxima das extremidades da imagem dificultando a leitura do calado, seja de forma automática ou manual.

O resultado obtido mostra a vantagem da utilização do rastreador. Entretanto, nota-se que a posição horizontal da marca de calado na imagem varia próximo aos limites da faixa de tolerância, nem sempre convergindo a zero e, portanto, mantendo um pequeno erro em relação ao centro




Figura 8. Posição horizontal das marcas no tempo.

da imagem. Isso ocorre por conta das limitações técnicas da câmera utilizada, que impossibilitam um ajuste fino.

Porém, vale ressaltar que essa diferença não é prejudicial para o processo de arqueação manual ou automatizado, pois a marcação do calado permanece próximo ao centro da imagem. Além disso, percebe-se que em momentos onde a imagem está parada por alguns segundos, a câmera é capaz de corrigir a sua posição de forma a manter a marca do calado na área de tolerância.

5. CONCLUSÃO

Neste trabalho foi proposto um sistema baseado em visão computacional para auxiliar a leitura de calado dos navios. O sistema é capaz de atuar na orientação de uma câmera com o intuito de manter a marcação de calado sempre no centro de sua imagem, facilitando a visualização e leitura da arqueação do navio.

A solução proposta apresentou resultados positivos, sendo capaz de auxiliar em aplicações autônomas de medição de calado, bem como facilitar o trabalho do operador no caso de uma aferição manual. Como inovação, essa solução traz um controle servo visual aplicado em ambientes portuários e na execução desta tarefa, abrindo portas para futuros desenvolvimentos e aplicações nesta área.

Ainda há espaço para melhorias, como por exemplo a substituição da câmera por um modelo que possibilita um ajuste fino e uma resposta mais rápida, permitindo a diminuição da região de tolerância.

Outra dificuldade encontrada foi a existência de problemas de comunicação entre a câmera e o microcontrolador Raspberry Pi, modelos 3B+ e 4, o que impossibilitou o consumo das imagens diretamente pelo microprocessador. Por causa disso, o algoritmo de rastreamento, que inicialmente estava embarcado no microcontrolador, teve de ser transferido para o servidor. Para comprovar tal limitação de comunicação, o sistema foi testado com outro modelo de câmera e não apresentou os problemas mencionados. Entretanto, a estrutura física e tamanho da mesma não permitia a sua utilização no protótipo desenvolvido. Assim, o funcionamento da aplicação em *edge computing* parece promissor, devido ao baixo custo computacional do rastreador, sendo esta uma das propostas para trabalhos futuros.

REFERÊNCIAS

- Chayeb, A., Ouadah, N., Tobal, Z., Lakrouf, M., and Azouaoui, O. (2014). Hog based multi-object detection for urban navigation. In *17th Int. IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2962–2967.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, volume 1, 886–893 vol. 1.
- Ferreira, J.L.H., Fernandes, M.R., dos Santos, C.C., and Vassallo, R.F. (2018). Character Recognition for automatic draught survey. *2018 13th IEEE Int. Conference on Industry Applications (INDUSCON)*, 10–22.
- Flores-Delgado, J.I., Martínez-Santos, L.G., Lozano, R., Gonzalez-Hernandez, I., and Mercado, D.A. (2017). Embedded control using monocular vision: Face tracking. In *2017 Int. Conference on Unmanned Aircraft Systems (ICUAS)*, 1285–1291.
- Gonzalez, R.C. and Woods, R.E. (2008). *Digital image processing*. Prentice Hall.
- Machado, F. (2020). *Medição Automática de Calado utilizando Deep Learning*. Master's thesis, Universidade Federal do Espírito Santo.
- Machado, F., dos Santos, C.C., and Vassallo, R.F. (2018). Reconhecimento de Linha d'água usando Filtros de gabor. *XXII Congresso Brasileiro de Automática - CBA 2018*.
- Ministério da Indústria, C.E.e.S. (2020). Comex stat. URL <http://comexstat.mdic.gov.br/pt/home>.
- OpenCV (2015). Open source computer vision library.
- Rastogi, A., Pal, A., and Ryuh, B.S. (2017). Real-time teat detection using haar cascade classifier in smart automatic milking system. In *2017 7th IEEE Int. Conference on Control System, Computing and Engineering (ICCSCE)*, 74–79.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788.
- Tsujii, T., Yoshida, H., and Iiguni, Y. (2016). Automatic draft reading based on image processing. *Optical Engineering*, 55(10), 104104.
- UNCTAD (2020a). *PORT MANAGEMENT SERIES*, volume 8. United Nations Publications, New York.
- UNCTAD (2020b). *REVIEW OF MARITIME TRANSPORT 2020*. October. United Nations Publications, New York.
- Viola, P. and Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, volume 1, I–I.
- Voigtlaender, P., Luiten, J., Torr, P.H.S., and Leibe, B. (2020). Siam r-cnn: Visual tracking by re-detection. In *CVPR*.
- Wanjale, K.H., Bhoomkar, A., Kulkarni, A., and Gosavi, S. (2013). Use Of Haar Cascade Classifier For Face Tracking System In Real Time Video. *Int. Journal of Engineering Research and Technology*, 2348–2353.
- Wojke, N., Bewley, A., and Paulus, D. (2017). Simple online and realtime tracking with a deep association metric. In *2017 IEEE Int. Conference on Image Processing (ICIP)*, 3645–3649.