

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

THAIS ZORAWSKI

**MÉTODO DE DETECÇÃO DE LINHA DO HORIZONTE EM IMAGENS
MARÍTIMAS BASEADO EM PROCESSAMENTO DE IMAGENS**

CAMPO MOURÃO

2022

THAIS ZORAWSKI

**MÉTODO DE DETECÇÃO DE LINHA DO HORIZONTE EM IMAGENS
MARÍTIMAS BASEADO EM PROCESSAMENTO DE IMAGENS**

Horizon Line Detection in Maritime Images Based on Image Processing

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Ciência da Computação do Curso de Bacharelado em Ciência da Computação da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Juliano Henrique Foleis

Coorientador: Prof. Dr. Diego Bertolini
Gonçalves

CAMPO MOURÃO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

THAIS ZORAWSKI

**MÉTODO DE DETECÇÃO DE LINHA DO HORIZONTE EM IMAGENS
MARÍTIMAS BASEADO EM PROCESSAMENTO DE IMAGENS**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Ciência da Computação
do Curso de Bacharelado em Ciência da
Computação da Universidade Tecnológica
Federal do Paraná.

Data de aprovação: 14/junho/2022

Andre Luiz Satoshi Kawamoto
Doutorado
Universidade Tecnológica Federal do Paraná

Eduardo Henrique Monteiro Pena
Doutorado
Universidade Tecnológica Federal do Paraná

Juliano Henrique Foleis
Doutorado
Universidade Tecnológica Federal do Paraná

CAMPO MOURÃO
2022

RESUMO

Contexto: A detecção da linha do horizonte é uma tarefa que pode ser empregada na área de realidade aumentada, na segurança de portos, navegação de embarcações e aeronaves autônomas, entre outras aplicações. Ela consiste no encontro da borda que faz a fronteira entre o céu e o não-céu. No processo de detecção da linha do horizonte no meio marítimo, elementos desafiadores podem aparecer, como neblina, mau tempo, vapor da água, reflexos e embarcações encobrendo a linha do horizonte. Métodos tradicionais do processamento de imagens, ao serem empregados de forma isolada, sem a utilização de outras técnicas e ferramentas, nem sempre conseguem lidar satisfatoriamente com esses desafios. Por outro lado, métodos que utilizam aprendizagem de máquina tem obtido taxas de acerto promissoras, porém, alguns desses métodos propostos envolvem operações complexas, como por exemplo as redes neurais artificiais profundas, e são executados em *GPUs*. Tendo em vista que aeronaves autônomas tem um hardware limitado e muitas vezes não contam com uma *GPU*, utilizar esses métodos pode não ser viável. **Objetivo:** Neste trabalho propõe-se um método de detecção da linha do horizonte para imagens marítimas utilizando processamento de imagens com métodos de apoio que podem ser implementados em dispositivos embarcados. **Método:** Utilizando a base de dados Singapore Maritime Dataset (SMD), foram utilizadas técnicas de processamento de imagens, como detecção de bordas, combinadas a outros métodos que não utilizam aprendizagem de máquina, como o Random Sample Consensus (RANSAC), para determinar a linha do horizonte em imagens marítimas. **Resultados:** o método proposto apresentou erro na determinação do ângulo abaixo de 1 grau para imagens *onboard* e entre 2.85 e 2.89 para imagens *onshore*, e menos de 5 pixels de diferença da linha real para a linha estimada para cinquenta por cento das imagens testadas. **Conclusões:** Apesar dos resultados obtidos pelo método proposto apresentarem uma taxa de erro superior ao atingido pelo estado da arte, ele pode traçar uma linha do horizonte aproximada e pode ser executado em dispositivos embarcados.

Palavras-chave: detecção da linha do horizonte; processamento de imagens; ransac; ambiente marítimo; .

ABSTRACT

Context: The detection of the horizon line is a task that can be used in augmented reality, in port security, in navigation of vessels and autonomous aircraft, among other applications. This line is the edge that forms the boundary between sky and non-sky areas. To find the horizon line can present some challenging elements, such as fog, bad weather, water vapor, reflections and some vessels covering the horizon line. Traditional image processing methods, when used individually, without the use of other techniques and tools, are not always able to satisfactorily deal with these challenges. On the other hand, methods that use machine learning are getting promising success rates, however, some of these proposed methods involve complex operations, such as deep learning networks, and are executed in *GPUs*. Since autonomous aircraft have limited hardware and often do not have a *GPU*, using these methods may not be feasible.

Objective: In this work we propose a horizon line detection method for maritime images using image processing with other methods as support that can be implemented in embedded devices.

Method: Using the SMD database, image processing techniques were used, such as edge detection, combined with other methods that do not use machine learning, such as RANSAC, to determine the horizon line in maritime images.

Results: the proposed method presented an error in determining the angle below 1 degree for *onboard* images and between 2.85 and 2.89 degrees for *onshore* images, and less than 5 pixels of difference from the real line for the estimated line for fifty percent of the tested images.

Conclusions: Although the results obtained by the proposed method present an error rate higher than that achieved by the state of the art methods, it can draw an approximate horizon line and can be executed in embedded devices.

Keywords: horizon line detection; image processing; ransac; maritime environment.

LISTA DE FIGURAS

Figura 1 – Imagem de ambiente marítimo.	10
Figura 2 – Imagem de ambiente marítimo com a linha do horizonte traçado em branco.	10
Figura 3 – Exemplo de oclusão na linha do horizonte. A linha do horizonte traçada pelo método de detecção encontra-se em vermelho. Por conta das características desafiadoras dessa imagem, o método não conseguiu delimitar o horizonte com eficiência.	11
Figura 4 – Anotações da máscara verdade da base de dados SMD. O ponto central da linha do horizonte é dado pelas coordenadas (X,Y), o qual chamaremos de P. Outra informação importante é a inclinação da linha do horizonte, representada por <i>alpha</i>	16
Figura 5 – Exemplo de operação de convolução. Em preto estão os pixels da imagem, em vermelho o <i>padding</i> . Em azul está a janela que percorre a imagem e separa os pixels para serem multiplicados pelo filtro de convolução.	20
Figura 6 – Exemplo de execução do algoritmo RANSAC: pontos iniciais em cinza.	21
Figura 7 – Exemplo de execução do algoritmo RANSAC: subconjunto de pontos selecionados em azul e linha estimada em vermelho.	22
Figura 8 – Imagem de meio marítimo	23
Figura 9 – Variações das Intensidades de Cor da Figura 8	23
Figura 10 – Convolução da Figura 9	24
Figura 11 – Limiarização da Figura 10	24
Figura 12 – Aplicação do RANSAC nos pixels estimados na transição entre céu e mar. Em amarelo estão os pontos do subconjunto de amostragem selecionados para a realização dos cálculos de estimativa da reta. Em azul estão o restante dos pontos, os quais não compõem o subconjunto de amostragem.	25
Figura 13 – Imagem com linha do horizonte estimada	26
Figura 14 – Exemplo de imagem <i>Onboard</i> da base de dados SMD	27
Figura 15 – Exemplo de imagem <i>Onshore</i> da base de dados SMD	28

Figura 16 – Histograma do erro do ângulo previsto (em graus) para as imagens <i>Onboard</i>	29
Figura 17 – Histograma do erro do ângulo previsto (em graus) para as imagens <i>Onshore</i>	30
Figura 18 – Histograma do erro do ponto central previsto (em pixels) para as imagens <i>Onboard</i>	30
Figura 19 – Histograma do erro do ponto central previsto (em pixels) para as imagens <i>Onshore</i>	31

LISTA DE TABELAS

Tabela 1 – Resultados do trabalho Liang e Liang (2020)	16
Tabela 2 – Resultados dos testes do método proposto por Jeong, Yang e Moon (2019) e Hough	17
Tabela 3 – Resultados dos testes do método proposto por Jeong, Yang e Moon (2018)	18
Tabela 4 – Resultados dos testes realizados por Ahmad <i>et al.</i> (2017). Os resultados apresentados correspondem aos métodos e as suas configurações que apresentaram os melhores resultados	19
Tabela 5 – Resultados dos experimentos do método proposto	29

LISTA DE ABREVIATURAS E SIGLAS

Siglas

CNN	Convolutional Neural Network
DDN	Deep Deconvolutional Networks
FCN	Fully Convolutional Network
GLCM	Matriz de Co-ocorrência de Níveis de Cinza
PSO	Particle Swarm Optimization
PSPNet	Pyramid Scene Parsing Network
RANSAC	Random Sample Concensus
SMD	Singapore Maritime Dataset
SVM	Support Vector Machine
VANT	Veículo Aéreo Não Tripulado

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Objetivos	10
1.2	Desafios	11
1.3	Motivação	11
1.4	Organização do Texto	12
2	ESTADO DA ARTE	13
2.1	Abordagens usando Detecção de Bordas	13
2.2	Abordagens usando segmentação por região	17
3	MÉTODO	20
3.1	Ferramental Matemático	20
3.1.1	Convolução	20
3.1.2	Limiarização	21
3.1.3	Algoritmo RANSAC	21
3.2	Método Proposto	22
3.2.1	Estimativa dos Pontos da Transição Entre Céu e Mar	22
3.2.2	Estimativa da Linha do Horizonte com RANSAC	25
4	RESULTADOS E DISCUSSÃO	27
4.1	Base de Dados	27
4.2	Experimentos e Resultados	28
4.3	Discussão	29
5	CONCLUSÕES	32
5.1	Sugestões para Trabalhos Futuros	32
	REFERÊNCIAS	33

1 INTRODUÇÃO

A detecção da linha do horizonte consiste no problema de detectar a fronteira entre as regiões céu e não-céu (terra, água ou montanhas) e é uma tarefa que tem ganhado importância nos últimos anos. Com muitas aplicações, a linha do horizonte pode ser usada na área de segurança de portos, no processo de detecção de embarcações e rastreamento de alvos, na navegação de embarcações autônomas ou de veículos da categoria Veículo Aéreo Não Tripulado (VANT), seja eles autônomos ou controlados remotamente, e até mesmo em atividades de realidade aumentada (AHMAD *et al.*, 2015b).

Os veículos da categoria VANT, a qual inclui os populares *drones*, são dispositivos que estão sendo cada vez mais usados. Um VANT pode ser controlado remotamente por um operador humano ou realizar seus voos de forma autônoma, sendo então classificado como uma aeronave autônoma. Veículos dessa categoria podem ser usados em diferentes áreas como geotecnologia, agricultura, segurança, lazer, resgate de pessoas em lugares de difícil acesso, entregas de mercadorias, para fins cinematográficos, entre outras aplicações (AHMAD *et al.*, 2017).

Um VANT pode ser empregado para avaliar as condições climáticas e ambientais de uma ilha longínqua, realizando um voo autônomo, por exemplo. Contudo, para que esse voo seja realizado de forma totalmente autônoma, esse veículo deve ser projetado para fazer o controle dos ângulos de arfagem e rolagem e evitar uma colisão com obstáculos de forma independente, sem interferência humana. Os ângulos de arfagem e rolagem podem ser aferidos através dos sensores da aeronave, todavia esses sensores não podem detectar o surgimento de obstáculos.

Ter informações sobre a linha do horizonte pode ser útil para a solução desse problema e também determinar os ângulos de arfagem e rolagem. Através da inclinação da aeronave em relação a linha do horizonte é possível determinar o quanto a aeronave deve se movimentar nos eixos transversal (correspondente ao ângulo de arfagem) ou longitudinal (correspondente ao ângulo de rolagem) (OREIFEJ; LOBO; SHAH, 2011). Ou ainda, o quanto ela deve subir para não colidir com uma parede de rochas.

Ao focar em imagens de meio marítimo, a linha do horizonte trata-se de uma linha reta, que separa o céu do não-céu (mar). A Figura 1 apresenta um exemplo de imagem em meio marítimo e a Figura 2 apresenta a mesma imagem com a linha do horizonte detectada.


Dadas as características desafiadoras de alguns cenários, como mau tempo, neblina, reflexos, ondas ou embarcações encobrendo o horizonte, métodos tradicionais de processamento de imagens, como *Canny* e *Hough*, sem a utilização de outras técnicas e ferramentas, nem sempre conseguem lidar satisfatoriamente com esses desafios e traçar a linha do horizonte com eficácia (LIFSHITZ; GERSHIKOV; MILGROM, 2013).

Por outro lado, nos últimos anos vem sendo propostos muitos métodos que utilizam aprendizagem de máquina profunda para essa tarefa, os quais tem obtido taxas de acerto promissoras. Todavia, alguns desses métodos, por envolver redes neurais convolucionais, por

Figura 1 – Imagem de ambiente marítimo.



Figura 2 – Imagem de ambiente marítimo com a linha do horizonte traçada em branco.



exemplo, necessitam de um maior poder computacional e suporte especial em *hardware* por meio de processadores vetoriais, visto que realizam operações mais complexas. Tendo em vista que aeronaves autônomas tem uma capacidade computacional limitada, utilizar métodos baseados em aprendizagem de máquina profunda pode não ser viável em alguns casos.

1.1 Objetivos

Este trabalho teve como objetivo principal propor um método de detecção da linha do horizonte para imagens marítimas utilizando processamento de imagens com métodos de apoio que podem ser implementados em dispositivos embarcados.

Para colaborar na busca pelo objetivo, houveram os seguintes objetivos secundários:

- Levantar quais as técnicas aplicadas pelos trabalhos estado da arte para a detecção da linha do horizonte;
- Estudar o emprego de técnicas de processamento de imagens para segmentar a imagem em regiões. Estas técnicas são necessárias para que elementos de uma mesma região (céu e não-céu) tenham suas diferenças atenuadas e se ressaltem suas características em comum.
- Utilizar o método RANSAC para a definição da linha do horizonte a partir da estimativa de onde as regiões céu e não-céu se interceptam.

1.2 Desafios

A detecção de bordas, também conhecida como reconhecimento arestas, é uma das operações básicas utilizadas na área de processamento de imagens digitais. Um dos detectores de bordas amplamente difundido é o método Canny. Todavia, nem sempre o detector de bordas Canny, de forma isolada, consegue ter um desempenho satisfatório, especialmente em imagens desafiadoras (LIFSHITZ; GERSHIKOV; MILGROM, 2013). Uma imagem pode ser desafiadora por diversas características, como por conta do mau tempo, neblina, luminosidade, reflexo, ondas, oclusão do horizonte, entre outras (JEONG; YANG; MOON, 2018).

Na tarefa de detectar linhas do horizonte, por exemplo, imagens de mau tempo tornam-se desafiadoras pois há muitas nuvens e neblina, o que torna a cor do céu bem próxima à cor do mar e as bordas que delimitam o céu e mar se tornam menos salientes, reduzindo as chances de serem detectadas pelo método Canny (LIANG; LIANG, 2020). Outro exemplo de desafio acontece em imagens em que ocorre a oclusão da linha do horizonte (KUMEECHAI; JIRIWIBHAKORN, 2019), em que a linha de fronteira entre o céu e o não-céu se torna menos evidente do que as bordas dos elementos que estão escondendo a linha do horizonte, o que pode ser visto na Figura 3.

Figura 3 – Exemplo de oclusão na linha do horizonte. A linha do horizonte traçada pelo método de detecção encontra-se em vermelho. Por conta das características desafiadoras dessa imagem, o método não conseguiu delimitar o horizonte com eficiência.



Fonte: (LIANG; LIANG, 2020).

1.3 Motivação

Diversas abordagens têm sido propostas ao longo dos anos, empregando diferentes métodos para realizar a detecção da linha do horizonte buscando alcançar uma maior eficácia em imagens desafiadoras. Trabalhos recentes utilizando aprendizagem de máquina apresentaram

acurácia muito superior aos trabalhos que aplicam processamento de imagens puro, até mesmo para cenários desafiadores. Entre os métodos neles empregados estão Particle Swarm Optimization (PSO), Convolutional Neural Network (CNN), Support Vector Machine (SVM), Deep Deconvolutional Networks (DDN), Pyramid Scene Parsing Network (PSPNet), Fully Convolutional Network (FCN) e *SegNet*.

Esses métodos têm se mostrado muito eficientes em tarefas complexas, como detecção de imagens e separações de regiões. Todavia, ao utilizar equipamentos que precisam detectar a linha do horizonte realizando o processamento em tempo real no *hardware* embarcado, como os VANTs autônomos, podem surgir algumas limitações, visto o baixo poder computacional desses equipamentos *versus* a quantidade de processamento e memória que alguns desses métodos necessitam. Neste contexto, a investigação de métodos que não utilizam aprendizagem de máquina é promissora e continua sendo explorada. Em virtude disso, o presente trabalho propõe o emprego de um método baseado em processamento de imagens para estimar a fronteira entre as regiões céu e não-céu e o otimizador RANSAC para estimar a equação da linha do horizonte. A idéia é prover uma alternativa que não dependa de *hardware* especializado que normalmente não está disponível em um sistema embarcado.

1.4 Organização do Texto

O documento encontra-se organizado da seguinte maneira: No Capítulo 2 apresentamos métodos atuais de detecção da linha do horizonte. O método proposto é apresentado no Capítulo 3, juntamente com a definição da base de dados que será empregada e uma breve descrição sobre o ferramental matemático utilizado. No Capítulo 4 são apresentados os experimentos e resultados obtidos, seguidos de uma discussão sobre os mesmos. O Capítulo 5 traz a conclusão e sugestões para trabalhos futuros.

2 ESTADO DA ARTE

Os métodos propostos para a detecção da linha do horizonte podem ser classificados de acordo com a técnica utilizada, sendo: detecção de bordas e segmentação por região (TIMOTHEATOS *et al.*, 2019). A seguir descreveremos importantes trabalhos que nortearam o desenvolvimento desta pesquisa.

2.1 Abordagens usando Detecção de Bordas

Nem sempre métodos tradicionais de processamento de imagens, como o Canny, conseguem ter um desempenho satisfatório na detecção da linha do horizonte ao serem utilizados sozinhos. Entretanto, pode-se atingir um bom resultado ao se empregar esses métodos de processamento de imagens juntamente com outras técnicas.

Trabalhos como os de Timotheatos *et al.* (2019), Ahmad *et al.* (2015b) e Liang e Liang (2020) utilizam o detector de bordas Canny para auxiliar no processo de detecção da linha do horizonte. Nestes trabalhos, o algoritmo de Canny foi usado para extrair as bordas das imagens, as quais foram processadas por métodos que selecionam um conjunto de bordas que dentre todas iriam compor a linha do horizonte.

Timotheatos *et al.* (2019) utilizam Canny e Hough na etapa inicial, de extração das bordas. O algoritmo PSO é utilizado em seguida para realizar a otimização da linha encontrada. PSO é um método bioinspirado baseado em voo de pássaros e movimento de cardumes de peixes, que conta com três elementos fundamentais: o espaço de elementos onde será realizada a busca, a função objetivo que será utilizada para realizar a busca e o critério de parada, para saber quando parar de procurar.

Para realizar os experimentos, os autores Timotheatos *et al.* (2019) empregaram a base de dados *Wild Dataset*. A base contém 300 imagens do meio urbano e um avaliador humano foi utilizado para julgar se a linha do horizonte traçada estava correta ou não. A acurácia dos três métodos utilizando o *Wild Dataset*, foram:

- 77,66% para o método proposto;
- 39,00% usando Hough;
- 62,66% usando uma CNN.

Também foram utilizadas imagens capturadas através de uma câmera posicionada em um VANT em movimento. Para avaliar os resultados usando as imagens capturadas diretamente do VANT foi calculada a diferença entre os ângulos de rolagem e arfagem obtidos pelos métodos e os ângulos reais, obtidos através do sistema do VANT. A diferença entre o ângulo de rolagem obtido pelos métodos e o ângulo de rolagem real foi: 1,55° para o método proposto e 8,02° para

o método Hough. Já a diferença entre o ângulo de arfagem obtido pelos métodos e o ângulo de rotação real foi: $1,04^\circ$ para o método proposto e $2,90^\circ$ para o método Hough.

Pode-se observar que para os dois casos de teste, com o *Wild Dataset* e com as imagens capturadas diretamente do VANT, o método de processamento de imagens Hough puro apresentou o menor desempenho em relação aos outros métodos empregando técnicas de aprendizagem de máquina.

No trabalho de Ahmad *et al.* (2014) também foi realizada a detecção das bordas utilizando o método Canny. Em seguida, foi feita uma seleção das bordas mais proeminentes a constituírem o horizonte usando-se o classificador SVM, produzindo assim um Mapa de Classificação de Bordas.

Foi empregado técnicas de programação dinâmica sobre esse mapa de bordas para encontrar o menor caminho. O menor caminho era então denotado como linha do horizonte. Foram utilizados nos conjunto de treinamento e de teste 45 imagens do banco de dados *Basalt Hills* (base de dados de meio montanhoso) e 80 imagens retiradas da internet, respectivamente. Apenas 9 imagens foram usadas para treino e as demais para teste. A média absoluta do erro para as imagens da base *Basalt Hills* foi de 0,57. Já para as imagens retiradas da internet, a média absoluta do erro foi de 0,87.

Em um outro trabalho do grupo, que não utilizou detecção de bordas, Ahmad *et al.* (2015a) em vez de utilizarem um Mapa de Classificação de Bordas, utilizam um Mapa de Classificação de Pixels. Na primeira etapa, o classificador é usado para obter a pontuação de cada pixel, ou seja, a chance de cada pixel pertencer à linha do horizonte, gerando assim o mapa. Esse mapa passa por uma redução, mantendo apenas os m pixels com pontuação mais alta de cada coluna da imagem.

Na etapa de pós-processamento técnicas de Programação Dinâmica são aplicadas para encontrar o menor caminho, o que resulta na linha detecção da linha do horizonte. Os dados de treino e teste são os mesmos ao Ahmad *et al.* (2014). A média absoluta do erro para o conjunto *Basalt Hills* foi de 1,01. Para as imagens da internet, a média absoluta do erro foi de 1,28.

Em um terceiro trabalho do grupo (AHMAD *et al.*, 2015b), os autores realizaram a fusão dos dois métodos anteriores(Ahmad *et al.* (2014) e Ahmad *et al.* (2015a)). A abordagem de fusão proposta, unindo o primeiro e o segundo método, Ahmad *et al.* (2015b) utilizou o classificador para gerar o Mapa de Classificação de Pixels e também extraiu as bordas das imagens. As bordas foram usadas para aumentar o peso dos pixels de bordas no mapa de classificação.

Feito isso, os passos seguintes foram os mesmos citados em Ahmad *et al.* (2014) e Ahmad *et al.* (2015a). Os dados de treino e teste são os mesmos dos dois trabalhos anteriores. A média absoluta do erro para o conjunto *Basalt Hills* foi de 0,73. Para as imagens da internet, a média absoluta do erro foi de 0,85. Nos três trabalhos, os métodos propostos, que utilizavam aprendizagem de máquina, performaram melhor que os métodos tradicionais, os quais não utilizavam métodos de aprendizagem de máquina.

O trabalho de Liang e Liang (2020) utilizou, além das bordas, características físicas da luz e informações contextuais, probabilísticas, das cores e textura, extraídas de cada imagem. Primeiramente, a imagem foi convertida para níveis de cinza e subdivida horizontalmente em 30 regiões. Assim, foram extraídas características usando o descritor de textura Matriz de Co-ocorrência de Níveis de Cinza (GLCM) e calculado o peso da textura de cada sub-região. Desta forma, utilizando-se dados de características físicas da luz, como comprimento de ondas perto da linha do horizonte por exemplo, foi possível calcular a probabilidade de cada sub-região pertencer ao céu ou ao mar. A partir dessas informações, era possível determinar, para cada imagem, a região onde estava a borda de encontro entre o céu e o mar.

Tendo essa região de encontro definida, a área de procura da linha do horizonte se tornava menor, diminuindo o custo computacional. Para análise dos resultados foram utilizadas três base de imagens de paisagem marítima: a de Buoy, a SMD, com imagens *Onshore* e *Onboard*, e uma base proposta pelos próprios autores. A taxa de acerto da região de encontro entre o céu e o mar apenas aceitou como corretas as regiões que continham a linha do horizonte completa, e foi a seguinte para as três bases:

- 100% para as imagens de Buoy;
- 99,90% para as imagens SMD-*Onshore*;
- 98,55% para as imagens SMD-*Onboard*;
- 97,84% para a base proposta.

A segunda etapa foi então localizar a linha do horizonte nessa região. Liang e Liang (2020) utilizaram Canny e Hough para gerar possíveis linhas candidatas à linha do horizonte. Para cada uma das linhas candidatas foi aplicado uma janela 5×5 , acima e abaixo da linha, deslizando da esquerda para a direita, a fim de calcular o valor médio dos níveis de cinza, o desvio padrão e o desvio padrão do peso da textura. Por fim, com esses três valores era determinada a linha do horizonte.

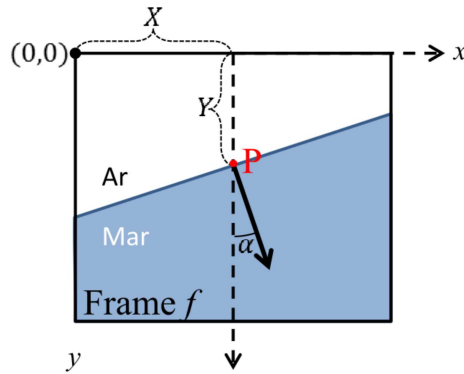
A análise de acerto da detecção da linha do horizonte levou em conta dois elementos:

- A distância entre os pontos centrais da linha do horizonte real e a linha do horizonte traçada pelo método. Veja a Figura 4;
- A diferença entre os ângulos de inclinação da linha do horizonte real e a linha do horizonte traçada pelo método.

Com essas duas informações é possível determinar a localização da linha do horizonte em uma imagem. Por esse motivo, o ponto central P e o ângulo de inclinação α são usados por diversos trabalhos como métricas de avaliação dos resultados.

A Tabela 1 apresenta uma comparação dos resultados da detecção da linha do horizonte para cada base de dados. Esse é um método que não utilizou técnicas de aprendizagem de

Figura 4 – Anotações da máscara verdade da base de dados SMD. O ponto central da linha do horizonte é dado pelas coordenadas (X,Y) , o qual chamaremos de P. Outra informação importante é a inclinação da linha do horizonte, representada por α .



P: ponto central da linha do horizonte

α : inclinação da linha do horizonte

Fonte: Base SMD.

máquina, ao invés disso reuniu diversas outras características e informações para poder traçar a linha do horizonte.

Tabela 1 – Resultados do trabalho Liang e Liang (2020)

Métricas	Conjuntos de imagens			
	Buoy	Proposto	SMD	
			Onshore	Onboard
Distância média do pixel central (pixel)	3,09	4,80	7,06	15,79
Diferença do angulo da linha (ângulo)	0,38	0,33	0,31	0,41

Jeong, Yang e Moon (2019) empregaram Canny para extrair bordas de imagens em várias escalas da dimensão da imagem e construíram um mapa de bordas multi-escala. A razão de se extrair bordas em diferentes escalas de uma imagem é reduzir a ambiguidade, inerente à métodos com uma única escala (WITKIN, 1983), e o custo computacional. Esse mapa de bordas foi submetido a uma CNN, a qual classificava os pixels entre linha do horizonte e não-linha do horizonte. Com os pixels classificados, no pós-processamento aplicou-se o ajuste de curva linear e um filtro da mediana para então determinar a linha do horizonte.

Para a realização do treinamento e teste foram utilizadas 20779 imagens da base de dados SMD, com imagens *Onshore* e *Onboard*. O erro foi calculado utilizando a distância do ponto central e a diferença na inclinação da reta. Os dados dos resultados foram apresentados em relação aos percentis, como demonstra a Tabela 2.

Pode-se observar que todos os trabalho apresentados até agora tinham uma forma diferente de avaliar o desempenho. Entre os trabalhos que utilizam a base de dados SMD é

Tabela 2 – Resultados dos testes do método proposto por Jeong, Yang e Moon (2019) e Hough

Métricas	Conjunto de imagens					
	Onshore			Onboard		
	25º percentil	50º percentil	95º percentil	25º percentil	50º percentil	95º percentil
Distância média do pixel central (pixel)	0,85	1,71	10,89	0,53	0,21	3,79
Diferença do ângulo da linha (ângulo)	0,03	0,12	0,82	0,04	0,10	0,38

consenso utilizar a distância do ponto central e a diferença na inclinação da reta, o que facilita a análise e comparação entre os resultados desses trabalhos.

Outro trabalho que utilizou um modelo baseado em CNN para detecção de bordas foi o de Porzi, Bulò e Ricci (2016), os quais propuseram uma etapa de treinamento apenas com as imagens e suas máscaras *ground-truth*. Os autores apresentaram uma DDN um modelo que contava com uma camada convolucional e outra camada deconvolucional. A rede proposta retornava uma máscara, com as mesmas dimensões da imagem, contendo a probabilidade de cada pixel pertencer a linha do horizonte. Essa máscara era então convertida em um grafo, na qual cada pixel era um nó, e era aplicada programação dinâmica para determinar o menor caminho, sendo este denominado como linha do horizonte.

A base de dados utilizada foi o *CH1 dataset* (base de imagens em meio montanhoso), do qual se extraiu 121 imagens, que com o uso de *data augmentation* totalizaram 203 imagens, em que 60% das imagens foram utilizadas para o treinamento do modelo e 40% para o teste. Como as imagens utilizadas eram de ambientes montanhosos, onde a linha do horizonte é definida como o encontro entre o céu e as montanhas, o horizonte não é uma linha reta e pode conter vários picos.

O erro foi medido em relação à distância de cada pixel predito pelo método até o pixel da máscara verdade do horizonte, para cada coluna. Essa é uma boa forma de medir o erro em bases de dados de imagens montanhosas, todavia já não se torna tão precisa ao ser usada para imagens de meio marítimo. O método proposto apresentou um erro médio de 1,53 pixels de distância.

2.2 Abordagens usando segmentação por região

A segmentação por região é uma abordagem que começou a ser aplicada na detecção da linha do horizonte recentemente, e vem apresentando bons resultados, como mostra literatura.

Jeong, Yang e Moon (2018) propuseram um método que utilizava uma PSPNet para separar o céu e o mar. Separadas essas duas regiões, o método localizava a máxima posição vertical correspondente ao mar para extrair a borda superior do mar na imagem. Como pós-

Tabela 3 – Resultados dos testes do método proposto por Jeong, Yang e Moon (2018)

Métricas	Conjunto de imagens					
	Onshore			Onboard		
	25 ^º percentil	50 ^º percentil	95 ^º percentil	25 ^º percentil	50 ^º percentil	95 ^º percentil
Distância média do pixel central (pixel)	0,81	1,64	5,59	0,52	1,45	3,81
Diferença do ângulo da linha (ângulo)	0,04	0,10	0,65	0,05	0,11	0,38

processamento, os autores propuseram aplicar iterativamente a regressão *least-square* e o filtro da mediana para determinar a linha do horizonte.

Jeong, Yang e Moon (2018) empregaram a base *ADE20K dataset* (base de dados de meio marítimo) para treinamento, a qual foi reduzida para seis classes pelos autores: céu, mar, navio, boia, cais e natureza. Para o conjunto de teste, a base SMD foi utilizada, com imagens *Onshore* e *Onboard*, com 15376 imagens. O erro foi medido utilizando a distância do ponto central e a diferença na inclinação da reta em relação aos percentis, como apresentado na Tabela 2.

Em Ahmad *et al.* (2017), os autores mudam a abordagem para segmentação por região e fazem uma comparação entre os métodos propostos por Long, Shelhamer e Darrell (2015) e Badrinarayanan, Kendall e Cipolla (2017) para a detecção da linha do horizonte. Os dois métodos são originalmente métodos de segmentação semântica e Ahmad *et al.* (2017) os adaptaram para detectar a linha do horizonte.

Long, Shelhamer e Darrell (2015) propuseram uma rede FCN, obtidas através da adaptação de outros classificadores CNN já existentes, realizando ajustes para a tarefa de segmentação. Em Ahmad *et al.* (2017) a FCN foi ainda ajustada com a base de imagens *CH1 dataset*, pois o modelo inicial não era adaptado para imagens de ambientes montanhosos, e o número de classes foi reduzido para apenas duas: céu e não-céu.

Já Badrinarayanan, Kendall e Cipolla (2017) propuseram uma rede chamada *SegNet*, que também foi baseada em *Fully Convolutional Layers*, porém mais focada em manter uma delimitação mais nítida, que é essencial para a segmentação de pixels em classes pequenas. Ahmad *et al.* (2017) também ajustou a *SegNet* utilizando a base de dados *CH1 dataset*, pois seu modelo inicial não era adaptado para imagens de ambientes montanhosos.

Ahmad *et al.* (2017) avaliou o desempenho das redes utilizando 2895 imagens extraídas da plataforma *Flickr*. A métrica para avaliar o desempenho foi o número de pixels rotulados corretamente em relação à máscara verdade. Os resultados das duas redes podem ser vistos na Tabela 4.

Ahmad *et al.* (2017) também avaliou algumas técnicas na etapa de pós-processamento. Entre as técnicas avaliadas, a que apresentou melhores resultados foi a que primeiramente eliminava todos os objetos não-céu menores que 50% do maior objeto não-céu e em seguida

Tabela 4 – Resultados dos testes realizados por Ahmad *et al.* (2017). Os resultados apresentados correspondem aos métodos e as suas configurações que apresentaram os melhores resultados

Métodos	Acurácia	Distância dos pixels	
		Média	Desvio padrão
SegNet	0,84	114,89	99,02
FCN	0,94	37,94	69,43

aplicava a detecção do horizonte por coluna. Ela encontrava o primeiro pixel não-céu de cada coluna, a partir do topo, e fixava todos os pixels abaixo como não-céu.

Por fim, vale ressaltar que cada trabalho discutido apresentou métodos de pós-processamento (que são técnicas aplicadas depois da classificação a fim de ajustar a linha do horizonte) diferentes. Isso demonstra uma grande variedade de técnicas para finalizar e realizar o ajuste da linha do horizonte. Outro ponto em destaque é que, redes convolucionais apareceram com frequência entre os métodos de detecção da linha do horizonte.

3 MÉTODO

Neste capítulo é apresentado um método baseado em processamento de imagens para detectar linhas do horizonte em imagens marítimas. Primeiramente são apresentadas as ferramentas matemáticas usadas no método. Em seguida, o método proposto é apresentado.

3.1 Ferramental Matemático

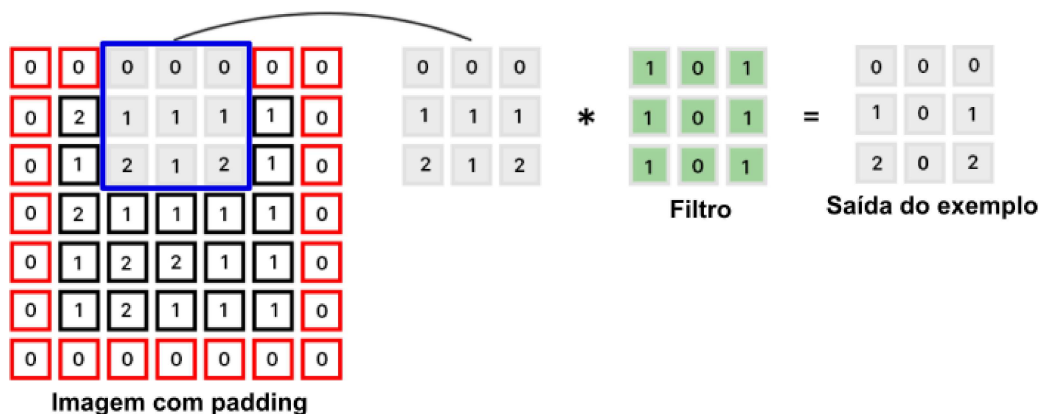
O ferramental matemático relacionado que fundamenta o método proposto neste trabalho é apresentado brevemente a seguir.

3.1.1 Convolução

A convolução é uma operação utilizada em imagens para atividades como detecção de padrões ou tratamento de imagens. Nessa operação, para cada pixel da imagem é aplicado um filtro, o qual é multiplicado pelos pixels adjacentes à posição atual, tendo como resultado o filtro de ativação para a detecção de uma determinada característica ou a imagem tratada. No presente trabalho, a convolução será utilizada para o tratamento da imagem, pois é necessário que as imagens sejam suavizadas para homogeneizar as regiões.

Ao aplicar uma convolução, a imagem é recebida como uma matriz. Uma segunda matriz é utilizada, que é o filtro, que salienta determinadas características ou realizará o tratamento da imagem, como a suavização das bordas, por exemplo. Durante a convolução, a matriz da imagem e a matriz do filtro são percorridas e cada posição da matriz resultante será a multiplicação dessas duas matrizes, ou seja, cada posição da nova matriz corresponderá ao valor da convolução naquele ponto. A Figura 5 apresenta um exemplo deste método.

Figura 5 – Exemplo de operação de convolução. Em preto estão os pixels da imagem, em vermelho o *padding*. Em azul está a janela que percorre a imagem e separa os pixels para serem multiplicados pelo filtro de convolução.



Fonte: Adaptado de Guibas e Virdi (2017).

Figura 6 – Exemplo de execução do algoritmo RANSAC: pontos iniciais em cinza.



Fonte: Aatoria própria (2022).

3.1.2 Limiarização


A técnica de limiarização, também chamada de *thresholding*, é o processo em que se utiliza um valor, chamado limiar, para limitar um conjunto de pontos e se aplicar determinadas operações. Neste trabalho a técnica de limiarização foi empregada para converter a imagem de escala de cinza para apenas preto e branco, resultando em uma imagem binária, diminuindo assim a sua complexidade.

Levando em consideração a escala de intensidade de cor de imagens cinzas, foi definido um valor para ser o limiar. Dessa forma, na execução dessa operação, pixels com intensidade superior ou igual ao limiar são convertidos para branco e pixels com valor inferior ao limiar são convertidos para preto.

3.1.3 Algoritmo RANSAC

Random Sample Consensus, ou RANSAC, é um método de reamostragem para a geração de modelos matemáticos com o mínimo de pontos possíveis. O algoritmo identifica pontos *outliers* e constrói o modelo excluindo esses pontos. Seu comportamento consiste em selecionar um subconjunto de pontos aleatórios, ajustar o modelo para esse subconjunto e calcular a quantidade de pontos não contemplados, ou seja, a quantidade de pontos desse subconjunto que não se encaixam no modelo construído. Esses passos são repetidos enquanto a razão dos pontos não contemplados for maior que um limiar, por um determinado número de vezes (DERPANIS,). As Figuras 6 e 7 demonstram um exemplo de execução do RANSAC.

Figura 7 – Exemplo de execução do algoritmo RANSAC: subconjunto de pontos selecionados em azul e linha estimada em vermelho.



Fonte: Autoria própria (2022).

3.2 Método Proposto

O método proposto consiste em duas fases. A primeira fase é composta de uma sequência de operações de processamento de imagem que estima, para cada coluna da imagem, o ponto onde há transição entre céu e mar. A segunda fase recebe a estimativa destes pontos e estima a equação da reta da linha do horizonte usando o algoritmo RANSAC.

3.2.1 Estimativa dos Pontos da Transição Entre Céu e Mar

A Figura 8 apresenta uma imagem do dataset SMD. O método será apresentado usando como exemplo esta imagem.

Ao analisar as imagens do *dataset*, notou-se que, em geral, a região do mar apresenta variações mais abruptas na intensidade das cores, enquanto esta variação na região de céu tende a ter variações mais suaves. Repare que por conta dessa maior variação de intensidade a região do mar apresenta mais bordas. Pode-se observar essa característica em áreas de mar por conta da movimentação das ondas, as quais refletem a luz em diferentes pontos e direções, resultando nessa característica.

Para quantificar as variações das intensidades de cor do céu e do mar, foi calculado o gradiente de cor em relação às linhas da imagem. Para isso, inicialmente a imagem é convertida para escalas de cinza para diminuir a complexidade da operação. Em seguida, uma nova imagem é gerada a partir subtração da intensidade dos pixels de dada linha $k - 1$ da linha k . A Figura 9 apresenta um exemplo de imagem gerada.

Figura 8 – Imagem de meio marítimo



Fonte: Base SMD.


Figura 9 – Variações das Intensidades de Cor da Figura 8




Fonte: Autoria própria.

O passo seguinte é aplicar três convoluções com o filtro da média 3×3 para suavizar as variações de intensidade dos pixels, tornando as regiões céu e não-céu mais homogêneas. Com isso, nota-se que a região correspondente ao céu torna-se mais escura como um todo, uma vez que a variação da intensidade dos pixels nessa região é mais baixa. Por outro lado, a região correspondente ao mar torna-se mais clara, correspondendo ao fato que a variação da intensidade dos pixels nessa região tende a ser mais alta. A Figura 10 mostra a imagem após esta etapa de suavização.

Uma estimativa das regiões correspondentes ao céu e ao mar pode ser obtida pela limiarização da imagem. Optou-se por usar o limiar 128, onde as intensidades menores ou iguais ao limiar foram atribuídas o valor 0, enquanto as intensidades maiores foram atribuídas o valor 255. Após a limiarização, a região do céu ficará em maior parte preta, enquanto a região do mar será majoritariamente branca, conforme mostra a Figura 11.

Figura 10 – Convolução da Figura 9


Fonte: Autoria própria.

Figura 11 – Limiarização da Figura 10

Fonte: Autoria própria.

Assim, para cada coluna, para determinar o possível pixel que compõe a linha do horizonte, ou seja, o pixel que marca a separação entre o céu e não-céu, é calculada a soma cumulativa dos pixels. Feito isso, obtém-se uma lista das somas cumulativas de cada coluna, com tamanho igual a quantidade de pixels das colunas da imagem. Para eliminar pequenas regiões de pixels brancos da área do céu, essas somas cumulativas são normalizadas e os dados menores que 0,05 são eliminados, para facilitar a detecção do pixel de separação. Visto que o céu sempre estará na área de cima da imagem, as posições iniciais da lista serão próximas de zero e passarão a ter valores maiores a partir do início da área não-céu. Considerando isso, o pixel de separação para cada coluna será a primeira posição diferente de zero encontrada na sua lista. A Figura 12 mostra um exemplo dos pontos de separação entre o céu e o mar encontrados pelo método proposto.

Figura 12 – Aplicação do RANSAC nos pixels estimados na transição entre céu e mar. Em amarelo estão os pontos do subconjunto de amostragem selecionados para a realização dos cálculos de estimativa da reta. Em azul estão o restante dos pontos, os quais não compõem o subconjunto de amostragem.



Fonte: Autoria própria.

3.2.2 Estimativa da Linha do Horizonte com RANSAC

A estimativa dos pixels estimados na transição entre céu e mar são usados para estimar a equação da reta que representa a linha do horizonte. A estimativa desta reta pode ser feita usando o método RANSAC. Para diminuir o custo computacional do método, 20% dos pixels da fronteira são amostrados. Um exemplo dessa amostragem são os pontos amarelos na Figura 12. Pode acontecer do RANSAC não convergir com dada amostragem. Quando isto acontece, uma nova amostragem é realizada e o RANSAC é executado novamente.

Para o subconjunto dos pixels amostrados na Figura 12, por exemplo, o coeficiente angular encontrado foi 0,00655 e o coeficiente linear foi 138,44740. Logo, a função da reta que representa a linha do horizonte é dada por $f(x) = 0,00655x + 138,44740$. Dada a função da reta, é possível determinar os pontos que constituem a linha do horizonte. Na Figura 12 a linha do horizonte é apresentada em vermelho.

Durante os testes, a equação da reta $f(x)$ estimada pelo RANSAC foi utilizada para encontrar o ponto central e o ângulo de inclinação, os quais foram utilizados para o cálculo do erro em relação à linha do horizonte real. A posição y do ponto central foi encontrado através de $f(x)$, em que x é a largura da imagem dividida por dois, ou seja, o valor de x na posição central. O ângulo da reta foi calculado a partir do arco-tangente do coeficiente angular.

Figura 13 – Imagem com linha do horizonte estimada



Fonte: Base SMD.

Para o exemplo da Figura 8, o erro da reta estimada em relação à reta real foi de 0,00160 graus para o ângulo de inclinação e 36,81807 pixels para a posição do pixel central. A Figura 13 mostra a imagem com a linha do horizonte estimada em vermelho. Repare a diferença do ângulo e inclinação.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os experimentos realizados, bem como os resultados obtidos.

4.1 Base de Dados

Neste trabalho foi empregada a base de dados SMD¹, proposta por Prasad *et al.* (2017). Essa base de dados é constituída de vídeos capturados nas águas de Singapura em diferentes rotas e localizações com diferentes condições. As imagens em alta resolução (1080 × 1920 pixels) foram capturadas antes do amanhecer (40 minutos antes do sol raiar), ao amanhecer, ao meio dia, à tarde, depois do por do sol (2 horas depois do sol se por), à noite e em dia com neblina e chuva, entre julho de 2015 e maio de 2016. Essas características proporcionaram uma grande variabilidade de imagens na base de dados, fazendo com que a mesma seja uma boa opção para avaliar métodos de detecção de linha do horizonte em imagens marítimas. As Figuras 14 e 15 apresentam duas imagens da base SMD.

Figura 14 – Exemplo de imagem *Onboard* da base de dados SMD



Fonte: Base SMD.

Os vídeos disponibilizados por essa base foram gravados sob duas perspectivas: *Onshore*, com a câmera fixa em terra firme, e *Onboard*, com a câmera em um barco em movimento. Devido à variação dos resultados apresentados pelos métodos usando imagens tiradas sob essas duas perspectivas, optamos por apresentar seus resultados separadamente, como no Capítulo 2. Por essa razão, ao longo do desenvolvimento deste trabalho também será adotada essa separação e os termos *Onshore* e *Onboard* serão usados para designar o método de aquisição das imagens.

¹ Disponível em <https://sites.google.com/site/dilipprasad/home/singapore-maritime-dataset>.

Figura 15 – Exemplo de imagem *Onshore* da base de dados SMD



Fonte: Base SMD.

A base de dados SMD disponibiliza anotações da posição da linha do horizonte, o que possibilita a construção da máscara verdade com os dois elementos essenciais para a detecção da linha do horizonte: céu e não-céu.

A escolha dessa base de dados se deu pelo fato dela ser pública e disponibilizar as anotações para a construção das máscaras verdade de cada imagem. O fato de ter sido utilizada por outros trabalhos desenvolvidos na área de detecção da linha do horizonte e disponibilizar uma grande quantidade de imagens (em comparação com outras bases utilizadas para a detecção da linha do horizonte) também influenciou para escolha da mesma.

4.2 Experimentos e Resultados

Os experimentos foram realizados com 13176 imagens da base Singapore Maritime Dataset (SMD), sendo 11707 *onshore* e 1469 *onboard*. Elas foram extraídas de 41 vídeos disponibilizados da base de dados, quadro a quadro, sendo 35 vídeos *onshore* e 6 vídeos *onboard*. Os vídeos da base que não tinham as anotações correspondentes à linha do horizonte para todos os seus *frames* foram desconsiderados. Originalmente os frames tinham a dimensão de 1920 pixels de largura e 1080 pixels de altura, porém para este trabalho as imagens foram redimensionadas para 400 pixels de largura e 225 pixels de altura, com o objetivo de reduzir o processamento.


Assim como os demais trabalhos já citados que também empregaram essa base em seus experimentos, os erros foram mensurados pela diferença da posição do ponto central e inclinação da reta traçada em relação a reta real, para as imagens *onshore* e *onboard*. Os erros por imagem foram sumarizados em quartis e serão apresentados a seguir. Para determiná-los, foram realizados diversos experimentos utilizando-se diferentes configurações dos métodos e combinações de parâmetros.

Tabela 5 – Resultados dos experimentos do método proposto

Métricas	Conjunto de imagens					
	Onshore			Onboard		
	25º percentil	50º percentil	95º percentil	25º percentil	50º percentil	95º percentil
Distância média do pixel central (pixel)	3,32	4,62	11,83	1.98	4.08	31,26
Diferença do ângulo da linha (graus)	2,88	2,88	2,88	0.21	0.23	0,25

Nas Figuras 16 e 17 pode-se ver um histograma com a distribuição dos erros dos ângulos encontrados para as imagens *onboard* e *onshore*, respectivamente. O eixo x representa o valor absoluto da diferença, em graus, do ângulo encontrado para o ângulo real. O eixo y representa a quantidade de ocorrências. Para gerar uma melhor visualização, os pontos *outliers* foram removidos.

Já nas Figuras 18 e 19 pode-se ver histograma com distribuição dos erros dos pontos centrais encontrados para as imagens *onboard* e *onshore*, respectivamente. O eixo x representa o valor absoluto da diferença, em pixels, da coordenada y do ponto encontrado para a do ponto real. O eixo y representa a quantidade de ocorrências. Para gerar uma melhor visualização, os pontos *outliers* foram removidos.


Figura 16 – Histograma do erro do ângulo previsto (em graus) para as imagens *Onboard*

Fonte: Autoria própria (2022).

4.3 Discussão


Analisando primeiramente os dados das imagens *onboard*, ao observar-se a distribuição dos erros mostrada na Figura 16 é possível notar que o erro do ângulo estimado ficou abaixo de 1 grau, tendo uma variação de 0,18 a 0,25. Percebe-se alguns picos ao redor dos pontos 0,20,

Figura 17 – Histograma do erro do ângulo previsto (em graus) para as imagens *Onshore*



Fonte: Autoria própria (2022).

Figura 18 – Histograma do erro do ponto central previsto (em pixels) para as imagens *Onboard*




Fonte: Autoria própria (2022).

0,21, 0,22, 0,23, 0,238 e 0,245. Isso pode ser causado pelo fato de haver seis vídeos *onboard* e, durante a gravação das imagens, como a câmera é fixa, há pouca deslocamento da linha do horizonte, ocasionando muitos quadros com a mesma inclinação da reta para um mesmo vídeo, tendo apenas deslocamento da localização do ponto central.

Em relação às imagens utilizadas, as imagens *onboard* foram as que mais se aproximaram dos resultados obtidos pelos trabalhos apresentados no Capítulo 2 que utilizavam aprendizagem de máquina. Já que os trabalhos apresentados anteriormente não utilizaram as mesmas dimensões das imagens utilizadas pelo presente trabalho e eles não deixam claro quais foram os vídeos utilizados para os experimentos e quais foram desconsiderados, não será realizada uma comparação mais profunda com trabalhos estado da arte.

Figura 19 – Histograma do erro do ponto central previsto (em pixels) para as imagens *Onshore*



Fonte: Autoria própria (2022).

Ao analisar o erro do ponto central, nota-se que para metade das imagens do conjunto de experimento o erro foi menor que 4 pixels, como mostrado na Tabela 5. Juntando com as informações trazidas pelo histograma da Figura 18, é possível verificar que o maior volume dos erros acontece até 15 pixels. Todavia, para algumas imagens, o erro gerado foi maior do que 30 pixels. Mais estudos poderiam ser realizados com o objetivo de verificar o que poderia ter provocado tal comportamento para as imagens *onboard*.

Os resultados da detecção da linha em imagens *onshore* exibem um comportamento diferente na distribuição dos erros do ângulo da reta estimada quando comparados com as imagens *onboard*. Neste conjunto, os erros dos ângulos apresentaram valor mínimo de 2.85 e valor máximo de 2.89. Ao olhar a Figura 17, salienta-se uma única barra, enfatizando a pequena distribuição dos erros. Esse comportamento também necessita de futuras análise para se poder precisar com exatidão a sua causa. Mesmo assim, ao comparar com os resultados dos trabalhos relacionados, é uma taxa de erro competitiva para a inclinação da reta.

Os erros do ponto central estimado para as imagens *onshore* se aproximam mais do apresentado pelas imagens *onboard*, porém com uma distribuição que se assemelha mais a uma gaussiana, como pode-se observar na Figura 19. Ao avaliar os dados da Tabela 5, observa-se que a grande maioria dos erros, cerca de 95%, estão abaixo de 12 pixels. Considerando que as imagens utilizadas nos experimentos tem 225 pixels de altura, 12 pixels podem representar uma grande distância da linha estimada para a linha real. Caso esses 12 pixels estejam acima da linha do horizonte real, representariam menor perigo, porém, se forem abaixo da linha do horizonte, haveria uma grande possibilidade de colisão nessa região. Entretanto, embora os erros da distância do pixel central estejam acima dos erros obtidos nos trabalhos relacionados, podemos considerar que aquelas abordagens necessitam de hardware embarcado especializado para operações matriciais.

5 CONCLUSÕES

Tendo em mente a limitação de *hardware* de VANTs e outros veículos autônomos, os quais não possuem *hardware* especializado para execução de métodos baseados em redes neurais profundas, o presente trabalho propôs um método para detecção da linha do horizonte baseado no processamento de imagens. A prioridade foi priorizar técnicas que não necessitassem de *hardware* especializado.

O método proposto divide o problema em duas etapas. Na primeira, os pixels da fronteira entre as regiões céu e não-céu foram estimados usando um procedimento baseado em operações clássicas de processamento de imagens. Na segunda etapa os pixels da fronteira são submetidos ao RANSAC, que estima um modelo linear correspondente à linha do horizonte.

Ao ser comparado com métodos do estado da arte que utilizam aprendizagem de máquina, o erro em relação ao ângulo de inclinação da linha do horizonte ficou próximo, apresentando números valores maiores. A diferença entre o ângulo de inclinação da reta proposta para a real foi inferior a 0,25 graus, taxa melhor que o trabalho de Jeong, Yang e Moon (2018), para imagens *onboard*, e se manteve entre 2.85 e 2.89 graus, para imagens *onshore*.

Todavia, em relação à posição do pixel central, o erro obtido pelo método proposto ainda é alto, dadas as taxas alcançadas pelos métodos do estado da arte. Diferentemente do erro da inclinação da reta, o erro em relação ao ponto central foi menor em imagens *onshore*, que obteve erros abaixo de 26.83 pixels (ao se eliminar os *outliers*). Já para as imagens *onboard*, o erro do pixel central permaneceu abaixo de 50.93 (ao se eliminar os *outliers*).

5.1 Sugestões para Trabalhos Futuros

Para trabalhos futuros poderia ser realizado um estudo mais aprofundado das imagens, em especial aquelas que apresentaram resultados fora da média, como aquelas que o resultados se encaixam como *outliers*. Seria interessante verificar quais são as características das imagens que produziram *outliers* e se essas características são comuns entre todas elas.

Também seria interessante realizar experimentos com imagens com áreas de tonalidades diferentes, como a Figura 1, na qual é possível identificar três grandes regiões na imagem. Nas imagens utilizadas para este trabalho, o tom predominante era o azul, porém o céu também pode assumir tons de rosa, roxo ou até amarelo-alaranjado, o que depende da disposição de nuvens do céu, de características físicas do ambiente e da posição do sol, por exemplo. Dados que em imagens como essa as áreas, além da diferença de tonalidade, podem também apresentar diferenças de textura causada pelo posicionamento das nuvens, por exemplo, pode ser que o método proposto tenha um comportamento diferente ao detectar qual é a linha que divide o céu do não-céu. Experimentos poderiam ser conduzidos para confirmar essa hipótese e criar insumos para propor um complemento ao método apresentado.

REFERÊNCIAS

- AHMAD, T. *et al.* An edge-less approach to horizon line detection. *In: 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*. [S.l.: s.n.], 2015. p. 1095–1102.
- AHMAD, T. *et al.* Fusion of edge-less and edge-based approaches for horizon line detection. *In: 2015 6th International Conference on Information, Intelligence, Systems and Applications (IISA)*. [S.l.: s.n.], 2015. p. 1–6.
- AHMAD, T. *et al.* An experimental evaluation of different features and nodal costs for horizon line detection. *In: .* [S.l.: s.n.], 2014. ISBN 978-3-319-14248-7.
- AHMAD, T. *et al.* Comparison of semantic segmentation approaches for horizon/sky line detection. *In: 2017 International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2017. p. 4436–4443.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 39, n. 12, p. 2481–2495, 2017.
- DERPANIS, K. G. **Overview of the RANSAC algorithm - York University**. Disponível em: http://www.cse.yorku.ca/~kosta/CompVis_Notes/ransac.pdf.
- GUIBAS, J.; VIRDI, T. **Convolutional Neural Networks Explained**. 2017. Disponível em: <https://twopointseven.github.io/2017-10-29/cnn/>.
- JEONG, C.; YANG, H. S.; MOON, K. A novel approach for detecting the horizon using a convolutional neural network and multi-scale edge detection. **Multidimensional Systems and Signal Processing**, v. 30, n. 3, p. 1187–1204, jul. 2019. ISSN 1573-0824. Disponível em: <https://doi.org/10.1007/s11045-018-0602-4>.
- JEONG, C. Y.; YANG, H. S.; MOON, K. D. Horizon detection in maritime images using scene parsing network. **Electronics Letters**, v. 54, n. 12, p. 760–762, 2018.
- KUMEECHAI, P.; JIRIWIBHAKORN, S. Effective horizon detection on complex seas using back propagation neural network. *In: 2019 16th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*. [S.l.: s.n.], 2019. p. 790–793.
- LIANG, D.; LIANG, Y. Horizon detection from electro-optical sensors under maritime environment. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 1, p. 45–53, 2020.
- LIFSHITZ, I.; GERSHIKOV, E.; MILGROM, B. **14. New Methods for Horizon Line Detection and Target Marking in Infrared and Visible Sea Images**. 2013. 334–348 p.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. *In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2015. p. 3431–3440.
- OREIFEJ, O.; LOBO, N.; SHAH, M. Horizon constraint for unambiguous uav navigation in planar scenes. *In: .* [S.l.: s.n.], 2011. p. 1159 – 1165.

PORZI, L.; BULÒ, S. R.; RICCI, E. A deeply-supervised deconvolutional network for horizon line detection. *In: Proceedings of the 24th ACM International Conference on Multimedia*. New York, NY, USA: Association for Computing Machinery, 2016. (MM '16), p. 137–141. ISBN 9781450336031. Disponível em: <https://doi.org/10.1145/2964284.2967198>.

PRASAD, D. K. *et al.* Video processing from electro-optical sensors for object detection and tracking in a maritime environment: A survey. **IEEE Transactions on Intelligent Transportation Systems**, v. 18, n. 8, p. 1993–2016, 2017.

TIMOTHEATOS, S. *et al.* Vision based horizon detection for uav navigation. *In: ASPRAGATHOS, N. A.; KOUSTOUMPARDIS, P. N.; MOULIANITIS, V. C. (Ed.). Advances in Service and Industrial Robotics*. Cham: Springer International Publishing, 2019. p. 181–189. ISBN 978-3-030-00232-9.

WITKIN, A. P. Scale-space filtering. *In: Proceedings of the Eighth International Joint Conference on Artificial Intelligence - Volume 2*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1983. (IJCAI'83), p. 1019–1022.